

Universidade Federal da Paraíba
Centro de Tecnologia
Programa de Pós-Graduação em Engenharia Mecânica
- Mestrado - Doutorado

DIAGNÓSTICO AUTOMÁTICO DE FALHAS EM ROLAMENTOS POR TEORIA DA INFORMAÇÃO E DINÂMICA NÃO LINEAR COM VALIDAÇÃO INDUSTRIAL

por

Paulo Roberto Lima Almeida

Tese de Doutorado apresentada à Universidade Federal da Paraíba para obtenção do grau de Doutor.

João Pessoa - Paraíba abril, 2026

Paulo Roberto Lima Almeida

DIAGNÓSTICO AUTOMÁTICO DE FALHAS EM ROLAMENTOS POR TEORIA DA INFORMAÇÃO E DINÂMICA NÃO LINEAR COM VALIDAÇÃO INDUSTRIAL

Tese apresentada ao curso de Pós-Graduação em Engenharia Mecânica da Universidade Federal da Paraíba, em cumprimento às exigências para obtenção do Grau de Doutor.

Orientador: Alisson Vasconcelos de Brito
Coorientador: Abel Cavalcante Lima Filho

João Pessoa - Paraíba abril, 2026

Catalogação na publicação
Seção de Catalogação e Classificação

A447d Almeida, Paulo Roberto Lima.
Diagnóstico automático de falhas em rolamentos por teoria da informação e dinâmica não linear com validação industrial / Paulo Roberto Lima Almeida. - João Pessoa, 2026.
340 f. : il.

Orientação: Alisson Vasconcelos de Brito.
Coorientação: Abel Cavalcante Lima Filho.
Tese (Doutorado) - UFPB/CT.

1. Rolamentos - Diagnóstico de falhas. 2. Teoria da informação. 3. Dinâmica não linear. 4. Limites teóricos. 5. Validação industrial. 6. Aprendizado de máquina - Diagnóstico. I. Brito, Alisson Vasconcelos de. II. Lima Filho, Abel Cavalcante. III. Título.

UFPB/BC CDU 621.822.7(043)

Elaborado por Larissa Silva Oliveira de Mesquita - CRB-15/746

DIAGNÓSTICO AUTOMÁTICO DE FALHAS EM ROLAMENTOS POR TEORIA DA INFORMAÇÃO E DINÂMICA NÃO LINEAR COM VALIDAÇÃO INDUSTRIAL

por

PAULO ROBERTO LIMA ALMEIDA

Tese aprovada em 29 de abril de 2026

Documento assinado digitalmente
gov.br
ALISSON VASCONCELOS DE BRITO
Data: 30/04/2026 19:39:11-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. Alisson Vasconcelos de Brito
Orientador – UFPB

Documento assinado digitalmente
gov.br
ABEL CAVALCANTE LIMA FILHO
Data: 29/04/2026 17:28:14-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. Abel Cavalcante Lima Filho
Coorientador – UFPB

Documento assinado digitalmente
gov.br
MOISES DANTAS DOS SANTOS
Data: 01/05/2026 10:17:41-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. Moises Dantas dos Santos
Examinador Interno – UFPB

Documento assinado digitalmente
gov.br
FRANCISCO ANTONIO BELO
Data: 01/05/2026 12:07:08-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. Francisco Antônio Belo
Examinador Interno – UFPB

Documento assinado digitalmente
gov.br
LEANDRO DIAS DA SILVA
Data: 01/05/2026 13:25:59-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. Leandro Dias da Silva
Examinador Externo – UFAL

Documento assinado digitalmente
gov.br
THYAGO LEITE DE VASCONCELOS LIMA
Data: 01/05/2026 15:30:50-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. Thyago Leite de Vasconcelos Lima
Examinador Externo – IFPB

João Pessoa - PB *2026*

DEDICATÓRIA

Dedico este trabalho para toda minha família, e especialmente aos meus pais, pelo incentivo incondicional em toda minha trajetória acadêmica.

AGRADECIMENTOS

Primeiramente, agradeço a Deus pela força, perseverança e serenidade concedidas ao longo desta jornada acadêmica.

Ao meu orientador, Prof. Dr. Alisson Vasconcelos de Brito, pela orientação precisa, pelos ensinamentos valiosos e pela confiança depositada em meu trabalho. Sua experiência e rigor científico foram fundamentais para o desenvolvimento desta tese.

Agradeço ao meu coorientador, Prof. Dr. Abel Cavalcante Lima Filho, pelo incentivo, pelas contribuições essenciais e pela constante disponibilidade em discutir aspectos técnicos do trabalho.

Aos professores do Programa de Pós-Graduação em Engenharia Mecânica da UFPB, pelos conhecimentos transmitidos ao longo das disciplinas e pelas discussões acadêmicas enriquecedoras.

Aos membros da banca examinadora, pela disponibilidade em avaliar este trabalho e pelas contribuições que certamente enriquecerão a versão final desta tese.

Aos colegas do Laboratório de Mecatrônica da UFPB, pelo apoio técnico na realização dos experimentos, na aquisição dos dados e pelas discussões que contribuíram para o refinamento das análises apresentadas.

À CAPES, pelo suporte financeiro ao Programa de Pós-Graduação em Engenharia Mecânica (PPGEM).

Aos meus pais, Maria de Lima Almeida e Júlio de Almeida Sousa (*in memoriam*), pelo incentivo constante e por sempre acreditarem no valor da educação e do conhecimento.

À minha família, pelo apoio emocional nos momentos de dificuldade e pela compreensão das ausências necessárias durante o desenvolvimento deste trabalho.

Aos meus colegas do Instituto Federal da Paraíba (IFPB), pela compreensão e apoio durante o período de realização do doutorado.

A todos que, direta ou indiretamente, contribuíram para a realização desta tese, meus sinceros agradecimentos.

DIAGNÓSTICO AUTOMÁTICO DE FALHAS EM ROLAMENTOS POR TEORIA DA INFORMAÇÃO E DINÂMICA NÃO LINEAR COM VALIDAÇÃO INDUSTRIAL

RESUMO

Esta tese desenvolve um arcabouço matematicamente fundamentado para o diagnóstico automático de falhas em rolamentos, integrando teoria da informação e dinâmica não linear para estabelecer limites teóricos de desempenho validados experimentalmente. A metodologia combina reconstrução do espaço de fase por imersão em coordenadas defasadas com um critério teórico-informacional para seleção dos parâmetros de reconstrução, extraindo invariantes dinâmicos como dimensão de correlação e expoente máximo de Lyapunov. Essas características são combinadas com coeficientes wavelet via maximização de informação mútua, resultando em ganhos de discriminabilidade de até 73% em relação ao uso isolado do espaço de fase. A principal contribuição consiste no estabelecimento e validação experimental de limites teóricos que relacionam a complexidade dinâmica ao desempenho de classificação, fornecendo garantias matemáticas explícitas. A validação experimental adota **estratégia quadripartite abrangente** em quatro conjuntos de dados complementares: UFPB, com acurácia de 97,27% em condições controladas; Fraunhofer LBF, com generalização de 91,1% em validação cruzada sob condições industriais reais; MFPT, confirmando transferibilidade entre sistemas com invariância morfológica artificial; e Paderborn, validando adaptabilidade a defeitos de fadiga natural. O método apresenta viabilidade industrial, com complexidade computacional compatível com aplicações em tempo real e quantificação explícita de incertezas.

Palavras-chave: Teoria da informação; Dinâmica não linear; Diagnóstico de falhas; Limites teóricos; Validação industrial.

DIAGNÓSTICO AUTOMÁTICO DE FALHAS EM ROLAMENTOS POR TEORIA DA INFORMAÇÃO E DINÂMICA NÃO LINEAR COM VALIDAÇÃO INDUSTRIAL

ABSTRACT

This thesis develops a mathematically grounded framework for automated bearing fault diagnosis by integrating information theory and nonlinear dynamics to establish theoretically derived performance limits validated experimentally. The methodology combines phase space reconstruction via time-delay embedding with an information-theoretic criterion for selecting reconstruction parameters, enabling the extraction of dynamical invariants such as correlation dimension and maximum Lyapunov exponent. These features are fused with wavelet coefficients through mutual information maximization, yielding discriminability gains of up to 73% compared to using phase space features alone. The main contribution lies in establishing and experimentally validating theoretical bounds that relate dynamical complexity to classification performance, providing explicit mathematical guarantees. Experimental validation follows a **comprehensive four-dataset strategy**: the UFPB dataset demonstrates methodological feasibility with accuracy of 97.27% under controlled conditions; the Fraunhofer LBF dataset evaluates industrial robustness, achieving 91.1% cross-validation under real operational conditions; the MFPT dataset confirms cross-system transferability with artificial morphological invariance; and the Paderborn dataset validates adaptability to naturally evolving faults. The proposed approach is both theoretically grounded and industrially viable, with computational complexity suitable for real-time applications and explicit uncertainty quantification.

Keywords: Information theory; Nonlinear dynamics; Fault diagnosis; Theoretical bounds; Industrial validation.

Sumário

Lista de Símbolos . . . . . **xxi**

Lista de Abreviaturas e Siglas . . . . . **xxvii**

1 INTRODUÇÃO **001**

1.1 Contextualização e Motivação 001

1.2 Problema de Pesquisa 002

1.2.1 Ausência de Garantias Teóricas de Desempenho 002

1.2.2 Seleção Heurística de Parâmetros 002

1.2.3 Integração Não Sistemática de Múltiplos Domínios de Análise . . . 002

1.2.4 Quantificação Inadequada de Incerteza 003

1.3 Objetivos 003

1.3.1 Objetivo Geral 003

1.3.2 Objetivos Específicos 003

1.4 Contribuições da Tese 004

1.4.1 Contribuições Científicas 004

1.4.2 Contribuições Metodológicas 006

1.4.3 Contribuições Práticas 006

1.5 Delimitação do Escopo 007

1.5.1 Plataformas Experimentais e Tipos de Componentes 007

1.5.2 Condições Operacionais 009

1.5.3 Justificativa das Delimitações 011

1.6 Organização da Tese 012

2 FUNDAMENTAÇÃO TEÓRICA **013**

2.1 Análise de Vibração em Rolamentos 013

2.1.1 Estrutura e Funcionamento de Rolamentos 013

2.1.2 Mecanismos de Geração de Vibração 015

2.1.3 Características de Sinais de Vibração em Rolamentos Defeituosos . 017
2.2 Dinâmica Não Linear e Teoria do Caos 022
2.2.1 Sistemas Dinâmicos e Espaço de Estados 022
2.2.2 Reconstrução do Espaço de Fase 022
2.2.3 Dimensão de Correlação 028
2.2.4 Expoente de Lyapunov 030
2.2.5 Análise de Recorrência 035
2.3 Teoria da Informação 039
2.3.1 Conceitos Fundamentais 039
2.3.2 Entropia Aproximada e Entropia Amostral 042
2.4 Análise Wavelet 042
2.4.1 Limitações da Transformada de Fourier 042
2.4.2 Transformada Wavelet Contínua 043
2.4.3 Wavelets Mães 043
2.4.4 Escalograma e Energia Wavelet 044
2.5 Aprendizado de Máquina para Diagnóstico 044
2.5.1 Aprendizado Supervisionado 044
2.5.2 Extreme Gradient Boosting (XGBoost) 044
2.5.3 Random Forest 045
2.5.4 Métodos Ensemble 045
2.5.5 Quantificação de Incerteza 045
2.6 Considerações Finais do Capítulo 046

3 REVISÃO BIBLIOGRÁFICA 048
3.1 Métodos Clássicos Aprimorados: Avanços e Limitações Persistentes . . . 048
3.1.1 Limitações Fundamentais Identificadas na Literatura Recente . . . 048
3.1.2 Avanços Recentes em Processamento de Sinais 049
3.1.3 Síntese: Limitações Fundamentais Persistem 051
3.2 Análise Tempo-Frequência Avançada 051
3.2.1 Limitações Teóricas Confirmadas 051
3.2.2 STFT Melhorada com Transformers 052
3.2.3 Wavelets com Seleção Automática de Parâmetros 052
3.2.4 Síntese: Avanços Técnicos, Limitações Teóricas Persistentes 053
3.3 Dinâmica Não Linear: Limitações Clássicas e Avanços Recentes 053
3.3.1 Limitações Históricas Persistentes 053
3.3.2 Avanços Recentes em Análise de Recorrência 053
3.3.3 Integração com Aprendizado de Máquina 054
3.3.4 Limitações Críticas Não Resolvidas 054
3.3.5 Síntese: Por que a Dinâmica Não Linear Ainda é Relevante? 055

3.4 Abordagens Guiadas por Teoria da Informação 055
3.4.1 Entropia como Medida de Complexidade 055
3.4.2 Fusão Multi-entropia e Análise da Informação 056
3.4.3 Lacunas Críticas Identificadas 057
3.4.4 Síntese: Potencial Não Realizado 058
3.5 Aprendizado de Máquina e Aprendizado Profundo: Desempenho vs. Fundamentação Teórica 059
3.5.1 Desempenho entre Conjuntos de Dados: Realidades e Limitações . 059
3.5.2 Lacunas Críticas Fundamentais 060
3.5.3 Síntese Comparativa: Aprendizado Profundo vs. Métodos Clássicos 060
3.6 Lacunas Identificadas e Motivação para a Arquitetura Proposta 061
3.6.1 Lacuna 1: Ausência de Limites Teóricos de Desempenho 061
3.6.2 Lacuna 2: Seleção Heurística de Parâmetros Críticos 062
3.6.3 Lacuna 3: Fusão Multi-Domínio Não-Sistemática 063
3.6.4 Lacuna 4: Quantificação da Incerteza Inexistente 063
3.6.5 Arcabouço Integrador Proposto 063
3.7 Considerações Finais do Capítulo 064

4 ARQUITETURA TEÓRICO-INFORMACIONAL PROPOSTA 067
4.1 Visão Geral e Arquitetura da Proposta 067
4.1.1 Motivação e Princípios Norteadores 067
4.1.2 Aquisição e Preparação dos Dados 069
4.1.3 Fluxo de Processamento de Diagnóstico 075
4.2 Limites Teóricos de Desempenho 076
4.2.1 Fundamentos Teórico-Informacionais 076
4.2.2 Interpretação Teórico-Informacional 076
4.2.3 Estimação de H(Y|X) via k-Nearest Neighbors 077
4.2.4 Limite de Desempenho para Ruído Aditivo 078
4.2.5 Quantificação de Deslocamento de Domínio via Desigualdade de Pinsker 078
4.2.6 Validação Empírica dos Limites 079
4.3 Otimização de Parâmetros Baseada na Teoria da Informação 079
4.3.1 Problema de Seleção de τ e m 079
4.3.2 Critério Baseado em Informação Mútua 080
4.3.3 Estimação Não-Paramétrica via KSG 080
4.3.4 Algoritmo de Busca em Grade 081
4.3.5 Comparação com Métodos Tradicionais 082
4.4 Extração de Características Não Lineares 083
4.4.1 Fluxo de Processamento de Computação 083

4.4.2 Vetor de Características Não Lineares 086
4.5 Análise Wavelet Adaptativa 087
4.5.1 Seleção Automática de Wavelet Mãe 087
4.5.2 Decomposição Multi-Resolução 088
4.5.3 Análise Tempo-Frequência via CWT 088
4.5.4 Extração de Características Wavelet 091
4.5.5 Vantagens sobre Análise Espectral Clássica 092
4.6 Fusão Teórico-Informacional de Características 093
4.6.1 Problema de Fusão Multi-Domínio 093
4.6.2 Critério mRMR 093
4.6.3 Análise Formal do Critério mRMR 094
4.6.4 Algoritmo Ganancioso (*Greedy*) de Seleção 094
4.6.5 Representação Característica Abrangente 095
4.6.6 Eficácia da Fusão Teórico-Informacional 096
4.6.7 Quantificação da Complementaridade Multi-Domínio 098
4.7 Classificação via XGBoost 099
4.7.1 Seleção do Classificador 099
4.7.2 Propriedades Específicas para Fusão Teórico-Informacional 100
4.7.3 Arquitetura e Hiperparâmetros 100
4.7.4 Validação Comparativa e Referência Inicial 102
4.7.5 Eficiência Computacional 102
4.8 Quantificação da Incerteza 105
4.8.1 Fundamentação Teórica da Decomposição da Incerteza 105
4.8.2 Implementação via Ensemble Bootstrap 107
4.8.3 Calibração e Estratégia Operacional 108
4.9 Considerações Computacionais 109
4.9.1 Análise de Convergência e Complexidade Temporal 109
4.9.2 Eficiência de Memória 112
4.9.3 Otimizações Implementadas 113
4.9.4 Compromissos Computacionais vs. Desempenho 114
4.10 Síntese e Contribuições do Capítulo 114
4.10.1 Contribuições Teóricas Fundamentais 114
4.10.2 Arquitetura Metodológica Integrada 115
4.10.3 Inovações Computacionais e Práticas 116
4.10.4 Estrutura de Validação Experimental 116
4.10.5 Síntese Integrativa e Próximos Passos 119

5 VALIDAÇÃO EXPERIMENTAL 120
5.1 Configuração Experimental 120

5.1.1 Motivação e Requisitos do Experimento 120
5.1.2 Descrição da Bancada de Testes 121
5.1.3 Protocolo de Indução de Defeitos 123
5.1.4 Condições Operacionais e Perfis de Carga 124
5.1.5 Estrutura do Conjunto de Dados e Protocolo de Validação 127
5.2 Resultados de Classificação 128
5.2.1 Desempenho Global dos Classificadores 128
5.2.2 Análise Detalhada por Classe 130
5.2.3 Matrizes de Confusão e Análise de Padrões de Erro 131
5.3 Validação dos Limites Teóricos de Desempenho 133
5.3.1 Fundamento Teórico Revisitado 133
5.3.2 Resultados de Validação Experimental 134
5.3.3 Interpretação Física e Discussão 135
5.4 Robustez à Variação de Carga Operacional 137
5.4.1 Estratificação por Nível de Carga e Perfil de Performance 137
5.4.2 Sensibilidade Específica por Tipo de Defeito 139
5.4.3 Implicações para Implantação Industrial 141
5.5 Análise da Incerteza e Calibração Probabilística 142
5.5.1 Decomposição Viés-Variância e Complementaridade de Classificadores 142
5.5.2 Quantificação da Incerteza: Decomposição Epistêmica versus Aleatória 144
5.5.3 Estratégia de Rejeição e Sistemas Híbridos Humano-Máquina . . . 146
5.5.4 Calibração Probabilística e Confiabilidade de Estimativas 147
5.6 Caracterização de Dinâmica Não Linear 149
5.6.1 Métricas de Estabilidade Dinâmica e Hierarquia de Complexidade . 149
5.6.2 Decaimento de Autocorrelação e Propriedades Ergódicas 151
5.6.3 Distribuição de Energia Tempo–Frequência via Wavelets 154
5.6.4 Reconstrução de Atratores em Espaço de Fase 157
5.7 Análise de Importância de Características e Fusão Multi-Domínio 159
5.7.1 Ordenação por Importância de Características e Interpretação Física 159
5.7.2 Sensibilidade ao Peso de Fusão e Validação de Abordagem Multi-Domínio 161
5.7.3 Análise do Horizonte de Predição e Estabilidade Temporal 164
5.7.4 Eficiência Computacional e Viabilidade de Tempo Real 166
5.8 Discussão Integrativa e Síntese de Resultados 168
5.8.1 Validação das Hipóteses de Pesquisa 168
5.8.2 Contribuições Científicas Principais 169
5.8.3 Contexto na Literatura e Comparações 169

5.8.4 Limitações e Direções Futuras 170
5.9 Considerações Finais do Capítulo 171
5.9.1 Síntese dos Resultados Principais 171
5.9.2 Contexto e Limitações da Validação UFPB 173
5.9.3 Transição para Validação de Robustez Industrial 174

6 Extensões Teórico-Informacionais e Robustez Industrial 176
6.1 Fundamentação do Arcabouço Teórico-Informacional 177
6.1.1 Erro de Bayes e Condições de Margem de Tsybakov 177
6.1.2 Separabilidade Multifractal e Redução de Entropia Condicional . . 180
6.1.3 Legitimação Teórica das Escolhas Metodológicas 182
6.1.4 Síntese: Fundamentação Teórico-Informacional 184
6.2 Implicações em Complexidade Amostral e Generalização 184
6.2.1 Limiares de Generalização via Teoria de Aprendizado Estatístico . 184
6.2.2 Análise de Curvas de Aprendizado e Requisitos Amostrais 187
6.2.3 Garantias de Generalização entre Domínios 190
6.2.4 Estratégias de Redução de Complexidade Amostral 191
6.3 Limites de Transferibilidade sob Heterogeneidade Representacional 195
6.3.1 Caracterização da Divergência Representacional 195
6.3.2 Estratégias de Harmonização Representacional 198
6.3.3 Implicações para o Projeto de Protocolos de Avaliação Diagnóstica 199
6.3.4 Síntese: Heterogeneidade Representacional como Fenômeno Distinto 200
6.4 Testes Teórico-Informacionais de Robustez Industrial 200
6.4.1 Fundamentação Teórica: Robustez como Preservação Informacional 200
6.4.2 Análise Teórico-Informacional de Tolerância a Ruído 202
6.4.3 Dados Faltantes como Canal de Apagamento 202
6.4.4 Falhas Multi-Sensor e Redundância Informacional 203
6.4.5 Generalização Entre Rolamentos sob Ótica Informacional 203
6.4.6 Avaliação de Proximidade aos Limites Informacionais 204
6.4.7 Síntese: Robustez como Propriedade Teórico-Informacional 204
6.5 Síntese Geral: Interpretação dos Resultados 204
6.5.1 Bloco I — Métrica Unificada de Proximidade a Limites de Referência 205
6.5.2 Bloco II — Mapa Consolidado de Discrepâncias Empírico–Teóricas 206
6.5.3 Bloco III — Fontes Dominantes de Discrepância 207
6.5.4 Bloco IV — Regimes de Operação e Limiares de Saturação 209
6.5.5 Bloco V — Síntese Conclusiva e Implicações 209

7 TRANSFERIBILIDADE ENTRE CONJUNTOS E INVARIÂNCIA DE MEDIÇÃO 211

7.1 Introdução 211
7.2 Arcabouço de Invariância de Características 212
7.2.1 Fundamentação Teórica 212
7.2.2 Seleção de Subconjunto Invariante 213
7.3 Validação Experimental entre Conjuntos de Dados 214
7.3.1 Configuração Experimental 214
7.3.2 Representação Teórico-Informacional 215
7.3.3 Métodos de Adaptação de Domínio 215
7.3.4 Validação Estatística Bootstrap 216
7.3.5 Adaptação de Domínio: Estado da Arte 216
7.4 Resultados e Análise 218
7.4.1 Identificação Empírica do Paradoxo 218
7.4.2 Condicionalidade Morfológica da Invariância 219
7.4.3 Análise Comparativa com o Estado da Arte 221
7.4.4 Implicação Teórica: Assimetria Fundamental 223
7.4.5 Colapsos de Métodos Sob Regimes de Baixa Amostragem 224
7.4.6 Robustez Estatística e Incerteza 224
7.4.7 Limites Empíricos de Transferibilidade e Papel da Invariância de Características 225
7.5 Interpretação Física e Teórica 231
7.5.1 Perspectiva de Teoria de Medição 231
7.5.2 Interpretação Física do Subconjunto Invariante 232
7.6 Limitações e Direções Futuras 233
7.6.1 Limitações Metodológicas 233
7.6.2 Direções Futuras 233
7.7 Considerações Finais do Capítulo 233

8 CONCLUSÕES E TRABALHOS FUTUROS 235

8.1 Recapitulação do Problema e Objetivos 235
8.2 Síntese das Contribuições Teóricas 236
8.2.1 Limites Teórico–Informacionais Fundamentais de Desempenho . . 236
8.2.2 Otimização Teórico-Informacional de Parâmetros 237
8.2.3 Fusão Multidomínio via mRMR Teórico-Informacional 238
8.2.4 Decomposição Formal da Incerteza via Conjunto Bootstrap 238
8.2.5 Arcabouço de Invariância de Medição e Condicionalidade Morfológica 239
8.3 Síntese dos Resultados Experimentais 239
8.3.1 Validação em Condições Controladas: Conjunto de Dados UFPB . 240
8.3.2 Validação de Robustez Industrial: Conjunto Fraunhofer 240

8.3.3 Validação de Transferibilidade entre Conjuntos de Dados: Invariância Morfológica . . . 241
8.3.4 Síntese da Estrutura Dual de Validação . . . 241
8.4 Resposta aos Objetivos Específicos . . . 242
8.4.1 Objetivo 1: Derivação de Limites Teóricos de Desempenho . . . 242
8.4.2 Objetivo 2: Critério Informacional-Teórico para Otimização de Parâmetros . . . 242
8.4.3 Objetivo 3: Arcabouço de Fusão Multidomínio . . . 243
8.4.4 Objetivo 4: Quantificação da Incerteza . . . 243
8.4.5 Objetivo 5: Validação Experimental Abrangente . . . 243
8.4.6 Objetivo 6: Arcabouço de Transferibilidade Cross-Dataset . . . 244
8.5 Implicações Científicas . . . 244
8.5.1 Fundamentação Matemática Rigorosa . . . 244
8.5.2 Unificação da Dinâmica Não Linear e Teoria da Informação . . . 245
8.5.3 Metodologia de Validação Rigorosa . . . 245
8.5.4 Extensibilidade a Outros Domínios . . . 246
8.5.5 Limites Fundamentais de Transferibilidade . . . 246
8.6 Implicações Práticas . . . 247
8.6.1 Manutenção Preditiva Certificável . . . 247
8.6.2 Redução de Custos Operacionais . . . 247
8.6.3 Implementação em Computação de Borda . . . 248
8.6.4 Aplicação em Energia Renovável . . . 249
8.6.5 Certificação de Transferibilidade Industrial . . . 249
8.7 Limitações e Trabalhos Futuros . . . 250
8.7.1 Limitações Reconhecidas . . . 250
8.7.2 Direções para Trabalhos Futuros . . . 251
8.8 Considerações Finais . . . 253

A Deduções Matemáticas e Demonstrações Auxiliares . . . 264
A.1 Dedução dos Limites Teórico-Informacionais de Fano . . . 264
A.1.1 Demonstração da Desigualdade de Fano para Classificação Multi-classe 264
A.1.2 Limite Inferior para a Probabilidade de Erro . . . 265
A.2 Demonstração das Propriedades do Expoente de Lyapunov . . . 266
A.2.1 Invariância do Maior Expoente de Lyapunov sob Mudança de Coordenadas . . . 266
A.3 Análise de Complexidade Computacional . . . 267
A.3.1 Complexidade Temporal . . . 267
A.3.2 Complexidade Espacial (Memória) . . . 269
A.3.3 Recomendações de Implementação . . . 270

A.4 Cálculo Detalhado da Dimensão de Correlação 271
A.4.1 Algoritmo de Grassberger-Procaccia 271
A.4.2 Estimação Robusta via Regressão Local 271
A.4.3 Correção de Theiler 271
A.5 Análise de Recorrência Quantificada: Demonstrações 272
A.5.1 Relação entre Taxa de Recorrência e Dimensão de Correlação . . . 272
A.5.2 Relação Qualitativa entre Determinismo e Expoente de Lyapunov . 272
A.6 Entropia Multiescala: Propriedades Assintóticas 273
A.6.1 Comportamento Assintótico para Sinais Estocásticos 273
A.6.2 Comportamento para Sinais Determinísticos 273
A.7 Análise Multifractal: Formalismo Completo 274
A.7.1 Método MF-DFA Passo a Passo 274
A.7.2 Relação com Espectro Multifractal 275
A.8 Validação Estatística: Intervalos de Confiança Bootstrap 275
A.8.1 Método Bootstrap Não-Paramétrico para Acurácia 275
A.8.2 Correção BCa (Bias-Corrected and Accelerated) 276
A.8.3 Teste de Significância para Diferença de Acurácias 276
A.9 Fluxo detalhado de processamento 276
A.10 Arcabouço de validação tripla 276

B Códigos de Implementação e Detalhes Experimentais 279
B.1 Implementação do Algoritmo de Lyapunov (Rosenstein) 279
B.2 Implementação da Análise de Recorrência 281
B.3 Parâmetros Experimentais Detalhados 286
B.3.1 Configuração de Hardware – Bancada UFPB 286
B.3.2 Protocolo de Indução de Defeitos 286
B.3.3 Perfil de Carga Variável 287
B.4 Estatísticas Descritivas Completas dos Conjuntos de Dados 288
B.4.1 Conjunto de Dados UFPB – Estatísticas de Vibração 288
B.5 Conjunto de Dados Paderborn – Defeitos Reais Progressivos 288
B.5.1 Especificações Técnicas do Sistema 289
B.5.2 Protocolo de Degradação Acelerada 290
B.5.3 Inventário Completo e Características dos Defeitos 291
B.5.4 Evolução Temporal dos Defeitos 292
B.5.5 Protocolo de Extração de Janelas Múltiplas 293
B.5.6 Comparação com Defeitos Artificiais 294
B.5.7 Estatísticas de Vibração por Condição de Defeito 295
B.5.8 Conjunto de Dados Fraunhofer LBF – Especificações Técnicas . . . 296
B.5.9 Conjunto MFPT (Machinery Failure Prevention Technology) 299

B.5.10 Conjunto IMS (Center for Intelligent Maintenance Systems) 300
B.6 Pseudocódigo do Fluxo Completo 303
B.7 Configuração de Hiperparâmetros do Gradient Boosting 304
B.7.1 Busca em Grade Realizada 304

Lista de Figuras

2.1 Geometria de um rolamento rígido de esferas 014
2.2 Defeitos artificiais em rolamentos do conjunto UFPB 014
2.3 Progressão temporal de defeitos em rolamentos 016
2.4 Sinais de vibração no domínio do tempo para três condições de operação do rolamento SKF 6206 018
2.5 Sinais de vibração do conjunto Paderborn com defeitos progressivos naturais 019
2.6 Sinais de vibração do dataset Fraunhofer LBF por classe de falha 020
2.7 Sinais de vibração do conjunto MFPT no domínio do tempo 021
2.8 Reconstrução do espaço de fase via incorporação por atraso temporal . . . 024
2.9 Efeito do atraso temporal τ na reconstrução do espaço de fase 024
2.10 Análise de falsos vizinhos para determinação da dimensão de imersão . . 026
2.11 Processo completo de reconstrução do espaço de fase 027
2.12 Espaços de fase reconstruídos: conjunto UFPB 028
2.13 Espaços de fase reconstruídos: conjunto Paderborn 029
2.14 Estimação de dimensão de correlação para o conjunto UFPB 029
2.15 Dimensão de correlação para o conjunto de dados Paderborn 030
2.16 Evolução temporal de perturbações para o conjunto UFPB 031
2.17 Expoente de Lyapunov para o conjunto Paderborn 032
2.18 Gráficos de recorrência do conjunto UFPB 036
2.19 Gráficos de recorrência do conjunto Paderborn 036
2.20 Diagrama de Venn ilustrando conceitos de teoria da informação 041

4.1 Arquitetura do arcabouço teórico–informacional proposto 070
4.2 Análise wavelet contínua (CWT) do conjunto de dados UFPB 089
4.3 Análise wavelet contínua (CWT) do conjunto de dados Paderborn 090
4.4 Ganho de informação mútua para diferentes conjuntos de características . 099

4.5 Decomposição da incerteza preditiva em componentes epistêmica (variabilidade entre modelos do ensemble) e aleatória (entropia preditiva) 106

5.1 Configuração da bancada experimental para diagnóstico de falhas em rolamentos 122
5.2 Perfis temporais de torque e distribuições estatísticas para as três condições de rolamento testadas. 125
5.3 Matrizes de confusão para classificação de defeitos em rolamentos com *Random Forest* e *XGBoost*. 131
5.4 Validação de limites teóricos versus erros experimentais para as três condições de rolamento. 136
5.5 Impacto da variação de carga na classificação de falhas em rolamentos . . 141
5.6 Decomposição viés-variância para *Random Forest* e *XGBoost*. 143
5.7 Análise de quantificação da incerteza epistêmica e aleatória para *Random Forest* e *XGBoost*. 145
5.8 Curvas de calibração para classificação de defeitos em rolamentos com três classes 148
5.9 Métricas de estabilidade dinâmica revelam hierarquia monotônica correlacionada com acurácia diagnóstica 150
5.10 (a) Médias temporais no espaço de estados reconstruído e (b) funções de autocorrelação correspondentes 152
5.11 (a) Médias móveis das séries temporais originais e (b) funções de autocorrelação associadas 153
5.12 Distribuição de energia normalizada por bandas de frequência obtida a partir dos sinais imersos no espaço de fase 155
5.13 Distribuição de energia normalizada por bandas de frequência obtida diretamente a partir dos sinais de vibração originais 156
5.14 Atratores em espaço de fase reconstruídos por imersão com atraso temporal para diferentes condições de rolamento 158
5.15 Ordenamento de importância das cinco características mais importantes para a classificação de defeitos em rolamentos: (a) Random Forest e (b) XGBoost. 160
5.16 Análise de sensibilidade ao peso de fusão α 162
5.17 Análise de estabilidade temporal para horizontes de predição de $t = 1$ a $t = 5$ passos 164

6.1 Distribuição empírica das margens de classificação 179
6.2 Análise de complexidade amostral via curvas de aprendizado 187
6.3 Aprendizado intra-domínio no Fraunhofer LBF 192

6.4 Dinâmica do aprendizado ativo no conjunto LBF 193
6.5 Caracterização empírica da divergência entre Paderborn e Fraunhofer . . . 197
6.6 Testes de robustez ambiental do arcabouço proposto 203
6.7 Convergência do índice informacional $\rho_{\mathrm{IT}} = I_{\mathrm{emp}}/H(Y)$ ao longo do aprendizado ativo no conjunto LBF (quatro classes) 206
6.8 Curvas de acurácia consolidadas no conjunto de teste em função do número de amostras rotuladas durante o aprendizado ativo no conjunto LBF (quatro classes) 207

7.1 Condicionalidade morfológica na transferibilidade entre conjuntos de dados 222
7.2 Comparação ilustrativa de desempenho entre métodos de adaptação de domínio para LBF→MFPT 223
7.3 Matriz de confusão para transferência LBF→MFPT com JDA 227
7.4 Análise expandida de transferibilidade incluindo direções N→N com o conjunto IMS 229
7.5 Estudo detalhado da transferência IMS→Paderborn (N→N) 230
7.6 Evolução temporal do *health indicator* (HI) baseado no RMS do envelope de Hilbert e da curtose no IMS 230
7.7 Health indicator (HI) baseado no RMS do envelope de Hilbert e curtose no conjunto Paderborn 231

A.1 Pipeline detalhado de processamento e extração de características 277
A.2 Arcabouço de validação tripla com protocolos complementares 278

B.1 Exemplos de defeitos reais em rolamentos do conjunto Paderborn 294
B.2 Configuração dos sensores na turbina eólica Fraunhofer LBF 297
B.3 Posicionamento dos acelerômetros nos rolamentos da turbina Fraunhofer . 298

Lista de Tabelas

2.1 Invariantes topológicos de dinâmica não linear 031
2.2 Invariantes topológicos de dinâmica não linear: dimensão de correlação (D_2), maior expoente de Lyapunov (λ_1), e entropia de Kolmogorov–Sinai (h_{KS}) para os conjuntos UFPB e Paderborn 033
2.3 Medidas de quantificação de recorrência (RQA) evidenciando a heterogeneidade dinâmica entre diferentes conjuntos de dados analisados 037

3.1 Desempenho de métodos clássicos aprimorados vs. aprendizado de máquina (2020-2025) 051
3.2 Aplicações recentes de RQA em diagnóstico de falhas em rolamentos (2020-2025) 054
3.3 Síntese de abordagens baseadas em entropia para diagnóstico de defeitos em rolamentos 058
3.4 Desempenho na validação entre conjuntos de dados: comparação sistemática061

4.1 Síntese dos parâmetros de pré-processamento aplicados 074
4.2 Análise de ablação da arquitetura modular proposta (conjunto UFPB) . . . 096
4.3 Latência de inferência por configuração de implantação 103
4.4 Complexidade temporal detalhada da cadeia de processamento 110
4.5 Escalabilidade computacional com número de classes 112
4.6 Configurações de implantação por cenário de aplicação. 114

5.1 Especificações da bancada experimental 123
5.2 Distribuição de amostras do conjunto de dados experimental 128
5.3 Comparação abrangente de desempenho entre classificadores 129
5.4 Desempenho detalhado por classe de defeito (*XGBoost*, 476 amostras de teste) 130

5.5 Validação abrangente dos limites teóricos de desempenho 134
5.6 Performance de Classificação Estratificada por Condição de Carga 138
5.7 Sensibilidade à Carga por Tipo de Defeito 139
5.8 Decomposição Viés-Variância para Algoritmos de Classificação 142
5.9 Decomposição da Incerteza: Componentes Epistêmica versus Aleatória . 144
5.10 Análise de compromisso acurácia versus taxa de rejeição (*XGBoost*). . . . 146
5.11 Decomposição do tempo computacional para o ciclo de inferência de uma amostra única 167
5.12 Comparação de desempenho e complexidade computacional no conjunto UFPB 172

6.1 Contribuição Informacional Diferencial por Domínio 181
6.2 Requisitos Amostrais para Tolerâncias de Performance Especificadas . . . 189
6.3 Dimensionalidade intrínseca e compressibilidade dos domínios 198
6.4 Métricas empírico-informacionais no conjunto LBF ao longo do aprendizado ativo (quatro classes). A **discrepância** ΔI coincide com a incerteza residual $\widehat{H}(Y \mid \tilde{X})$ devido a $H(Y) = \log_2 4 = 2.0$ bits. 208

7.1 Comparação de métodos de adaptação de domínio 218
7.2 Desempenho de transferibilidade entre conjuntos (Macro-F1) 221

A.1 Complexidade computacional dos métodos de extração de características . 268
A.2 Requisitos de memória por componente do Arcabouço 270

B.1 Especificações técnicas detalhadas da bancada experimental UFPB. 286
B.2 Estatísticas descritivas das séries temporais de vibração (aceleração em g) para cada condição dos dados UFPB. 288
B.3 Inventário completo do conjunto de dados Paderborn com características detalhadas dos defeitos reais. 291
B.4 Classificação de severidade baseada em dimensões dos defeitos (rolamento FAG 6203). 292
B.5 Comparação entre características de defeitos artificiais (UFPB) e reais (Paderborn). 294
B.6 Estatísticas descritivas dos sinais de vibração por tipo de defeito no conjunto Paderborn (aceleração em unidades normalizadas). 295
B.7 Especificações técnicas da turbina eólica Fraunhofer LBF (750 W). 296
B.8 Cenários de defeitos implementados no dataset Fraunhofer LBF. 298
B.9 Especificações geométricas do rolamento NICE (conjunto MFPT) 300
B.10 Frequências características de defeito (conjunto MFPT, 25 Hz) 300

B.11 Especificações geométricas e operacionais do rolamento Rexnord ZA-2115 utilizado no conjunto IMS 301
B.12 Configuração de sensores (conjunto IMS) 301
B.13 Frequências características de defeito (conjunto IMS, calculadas) 302
B.14 Espaço de busca de hiperparâmetros para otimização via validação cruzada 5 dobras. 304

LISTA DE SÍMBOLOS

SÍMBOLOS LATINOS

a	Aceleração (m/s^2)
A	Acurácia de classificação, constante de proporcionalidade (curvas de aprendizado)
c	Parâmetro de forma da distribuição, constante
$C(r)$	Soma de correlação em função do raio r
d	Diâmetro dos elementos rolantes (mm)
D	Diâmetro do *pitch circle* (círculo primitivo) do rolamento (mm)
D_2	Dimensão de correlação (Grassberger-Procaccia)
$d_{\mathcal{H}\Delta\mathcal{H}}$	Divergência $\mathcal{H}\Delta\mathcal{H}$ entre domínios
DET	Determinismo (métrica RQA, %)
E	Variável indicadora de erro de classificação
f	Frequência (Hz)
f_s	Frequência de amostragem (Hz), frequência de rotação do eixo (Hz)
$f_{\mathbf{BPFI}}$	Frequência característica de defeito na pista interna (*Ball Pass Frequency Inner race*, Hz)
$f_{\mathbf{BPFO}}$	Frequência característica de defeito na pista externa (*Ball Pass Frequency Outer race*, Hz)
$f_{\mathbf{BSF}}$	Frequência característica de defeito em elemento rolante (*Ball Spin Frequency*, Hz)

$f_{\mathbf{FTF}}$	Frequência da gaiola (*Fundamental Train Frequency*, Hz)
$F_q(s)$	Função de flutuação de ordem q na escala s (MFDFA)
$h(q)$	Expoente de Hurst generalizado de ordem q
H	Expoente de Hurst, entropia de Shannon (bits)
$H(X)$	Entropia de Shannon da variável aleatória X (bits)
$H(Y\|X)$	Entropia condicional de Y dado X (bits)
$I(X;Y)$	Informação mútua entre X e Y (bits)
K	Número de classes
K_2	Entropia de Kolmogorov-Sinai (bits/s)
l	Comprimento de linha diagonal (RQA)
$l_{\min}$	Comprimento mínimo de linha diagonal (RQA)
L	Comprimento médio de linha diagonal (RQA)
$L(\hat{f}_n)$	Erro de generalização do classificador empírico $\hat{f}_n$
L^*	Erro assintótico, limite inferior do erro de generalização
$\hat{L}_n(\hat{f}_n)$	Erro empírico do classificador sobre n amostras
$L_{\max}$	Comprimento máximo de linha diagonal (RQA)
LAM	Laminaridade (métrica RQA, %)
$\ell(\hat{y}, y)$	Função de perda (tipicamente 0-1 para classificação)
m	Dimensão de imersão (reconstrução do espaço de fase)
n	Índice temporal, número de amostras
N	Número total de pontos na série temporal
N_b	Número de elementos rolantes (esferas)

P_e	Probabilidade de erro de classificação
$P_{X,Y}$	Distribuição de probabilidade conjunta de entrada e saída
q	Ordem do momento estatístico (análise multifractal)
r	Raio de tolerância (entropia), distância no espaço de fase
R	Matriz de recorrência
RR	Taxa de recorrência (*Recurrence Rate*, %)
s	Escala temporal (entropia multiescala, análise multifractal)
t	Tempo (s)
T	Torque (N·m), período (s)
TT	Tempo de aprisionamento (*Trapping Time*, RQA)
v	Comprimento de linha vertical (RQA)
$x[n]$	Série temporal discreta, amostra no instante n
$x(t)$	Sinal temporal contínuo
X	Matriz de dados no espaço de fase reconstruído, variável aleatória de entrada
y	Classe verdadeira, variável de saída
$Y(i)$	Perfil cumulativo (análise multifractal)
$\hat{y}$	Classe predita, estimativa da variável de saída
$\mathcal{D}_n$	Conjunto de treinamento com n amostras
$\mathcal{F}$	Espaço de hipóteses, classe de funções candidatas
$\mathcal{H}$	Classe de hipóteses (contexto de teoria de aprendizado)
$\mathcal{M}$	Variedade latente comum entre domínios
$\mathcal{X}$	Espaço de características
$\mathbf{VCdim}(\mathcal{F})$	Dimensão Vapnik-Chervonenkis do espaço de hipóteses $\mathcal{F}$

SÍMBOLOS GREGOS

α	Expoente de singularidade local (análise multifractal), nível de significância estatística
$\alpha_{\min}$	Expoente de singularidade mínimo
$\alpha_{\max}$	Expoente de singularidade máximo
β	Expoente de convergência (curvas de aprendizado)
δ	Nível de confiança estatística ($1-\delta$ = probabilidade de sucesso), perturbação infinitesimal, incremento
$\Delta\alpha$	Largura do espectro multifractal ($\alpha_{\max}-\alpha_{\min}$)
ϵ	Tolerância de performance especificada, taxa de convergência
ε	Raio de vizinhança (análise de recorrência), parâmetro de tolerância
ε_n	Termo de erro aleatório com média zero
λ	Expoente de Lyapunov (bits/s ou s^{-1})
$\lambda_{\max}$	Maior expoente de Lyapunov (bits/s ou s^{-1})
λ^*	Erro conjunto mínimo (teoria de adaptação de domínio)
μ	Média aritmética
π	Distribuição *a priori* (teoria PAC-Bayesiana)
ρ	Distribuição *a posteriori* (teoria PAC-Bayesiana)
σ	Desvio padrão
σ^2	Variância
τ	Atraso temporal (amostras ou segundos)
ϕ	Ângulo de contato do rolamento (graus)
ϕ_t	Fluxo do sistema dinâmico no tempo t

Θ	Função de Heaviside (função degrau unitário)
ω	Frequência angular (rad/s)

OPERADORES E NOTAÇÕES MATEMÁTICAS

$\approx$	Aproximadamente igual
exp	Função exponencial
$\exists$	Existe
$\forall$	Para todo
$\in$	Pertence a
$\langle \cdot \rangle$	Média temporal ou ensemble
lim	Limite
ln	Logaritmo natural (base e)
log	Logaritmo na base 2 (teoria da informação) ou natural (análise matemática)
∇	Operador gradiente
$O(\cdot)$	Notação de ordem de grandeza assintótica (Big O)
$P(\cdot)$	Função de probabilidade
$\partial / \partial x$	Derivada parcial em relação a x
$\prod$	Produtório
$\propto$	Proporcional a
$\Rightarrow$	Implica logicamente
$\rightarrow$	Implica, mapeia para
$\sim$	Distribuído como, proporcional a
$\square$	Fim de demonstração (Q.E.D.)

$\subset$	Subconjunto de
$\sum$	Somatório
$\dot{x}$	Derivada temporal de x (dx/dt)
$\lvert\cdot\rvert$	Valor absoluto, cardinalidade de conjunto
$\lVert\cdot\rVert$	Norma Euclidiana
$\lVert\cdot\rVert_F$	Norma de Frobenius (para matrizes)
$\mathbb{E}[\cdot]$	Valor esperado (esperança matemática)
$\mathbb{N}$	Conjunto dos números naturais
$\mathbb{R}$	Conjunto dos números reais
$\mathbb{R}^n$	Espaço Euclidiano n-dimensional
$\mathbf{1}[\cdot]$	Função indicadora (vale 1 se condição é verdadeira, 0 caso contrário)
$\mathrm{KL}(\rho\lVert\pi)$	Divergência de Kullback-Leibler entre distribuições ρ e π

LISTA DE ABREVIATURAS E SIGLAS

ADC	*Analog-to-Digital Converter* (Conversor Analógico-Digital)
AI	*Artificial Intelligence* (Inteligência Artificial)
AMI	*Average Mutual Information* (Informação Mútua Média)
ANOVA	*Analysis of Variance* (Análise de Variância)
ApEn	*Approximate Entropy* (Entropia Aproximada)
BCa	*Bias-Corrected and Accelerated* (Correção de Viés e Aceleração)
BPFI	*Ball Pass Frequency Inner race* (Frequência de Passagem da Esfera pela Pista Interna)
BPFO	*Ball Pass Frequency Outer race* (Frequência de Passagem da Esfera pela Pista Externa)
BSF	*Ball Spin Frequency* (Frequência de Rotação da Esfera)
CCA	*Canonical Correlation Analysis* (Análise de Correlação Canônica)
CNN	*Convolutional Neural Network* (Rede Neural Convolucional)
CPU	*Central Processing Unit* (Unidade Central de Processamento)
CWRU	*Case Western Reserve University* (Universidade Case Western Reserve)
DC	*Direct Current* (Corrente Contínua)
DET	*Determinism* (Determinismo)
DFT	*Discrete Fourier Transform* (Transformada Discreta de Fourier)
EDM	*Electrical Discharge Machining* (Usinagem por Eletroerosão)

EES *Elsevier Editorial System* (Sistema Editorial Elsevier)

EMD *Empirical Mode Decomposition* (Decomposição em Modos Empíricos)

ERP *Enterprise Resource Planning* (Planejamento de Recursos Empresariais)

FFT *Fast Fourier Transform* (Transformada Rápida de Fourier)

FNN *False Nearest Neighbors* (Falsos Vizinhos Mais Próximos)

FTF *Fundamental Train Frequency* (Frequência Fundamental da Gaiola)

GBM *Gradient Boosting Machine* (Máquina de Gradient Boosting)

GPU *Graphics Processing Unit* (Unidade de Processamento Gráfico)

H *Healthy* (Saudável, sem defeito)

IAAFT *Iterated Amplitude Adjusted Fourier Transform* (Transformada de Fourier Iterada com Ajuste de Amplitude)

ICP *Integrated Circuit Piezoelectric* (Piezoelétrico de Circuito Integrado)

IR *Inner Race* (Pista Interna)

IR_MI *Inner Race with Mechanical Imbalance* (Pista Interna com Desbalanceamento Mecânico)

K-S Kolmogorov-Sinai

LAM *Laminarity* (Laminaridade)

LBF Laboratorium für Betriebsfestigkeit (Laboratório Fraunhofer de Durabilidade Estrutural)

LIME *Local Interpretable Model-agnostic Explanations* (Explicações Locais Interpretáveis Agnósticas ao Modelo)

LOBO *Leave-One-Bearing-Out* (Validação Cruzada Deixando um Rolamento de Fora)

LSTM *Long Short-Term Memory* (Memória de Curto-Longo Prazo)

MCSA *Motor Current Signature Analysis* (Análise de Assinatura de Corrente do Motor)

MF-DFA *Multifractal Detrended Fluctuation Analysis* (Análise de Flutuação Destendenciada Multifractal)

MFPT *Machinery Failure Prevention Technology*

MFXDFA *Multifractal Cross-Detrended Fluctuation Analysis* (Análise de Flutuação Cruzada Destendenciada Multifractal)

ML *Machine Learning* (Aprendizado de Máquina)

MMD *Maximum Mean Discrepancy* (Discrepância Máxima de Médias)

MSE *Multiscale Entropy* (Entropia Multiescala), *Mean Squared Error* (Erro Quadrático Médio)

NBR Norma Brasileira

OR *Outer Race* (Pista Externa)

PAC *Probably Approximately Correct* (Provavelmente Aproximadamente Correto)

PCA *Principal Component Analysis* (Análise de Componentes Principais)

PDF *Probability Density Function* (Função Densidade de Probabilidade)

PPGEM Programa de Pós-Graduação em Engenharia Mecânica

Q.E.D. *Quod Erat Demonstrandum* (Como Queríamos Demonstrar)

RE *Rolling Element* (Elemento Rolante)

ReLU *Rectified Linear Unit* (Unidade Linear Retificada)

RF *Random Forest* (Floresta Aleatória)

RMS *Root Mean Square* (Raiz Quadrática Média)

ROC *Receiver Operating Characteristic* (Característica de Operação do Receptor)

RPM *Rotations Per Minute* (Rotações Por Minuto)

RQA *Recurrence Quantification Analysis* (Análise de Quantificação de Recorrência)

RUL *Remaining Useful Life* (Vida Útil Remanescente)

SampEn *Sample Entropy* (Entropia Amostral)

SHAP *SHapley Additive exPlanations* (Explicações Aditivas de Shapley)

SKF Svenska Kullagerfabriken (Fábrica Sueca de Rolamentos de Esferas)

SNR *Signal-to-Noise Ratio* (Relação Sinal-Ruído)

STFT *Short-Time Fourier Transform* (Transformada de Fourier de Tempo Curto)

SVM *Support Vector Machine* (Máquina de Vetores de Suporte)

TDA *Topological Data Analysis* (Análise Topológica de Dados)

TT *Trapping Time* (Tempo de Aprisionamento)

UBC Union Bearings Corporation

UFPB Universidade Federal da Paraíba

VAE *Variational Autoencoder* (Autocodificador Variacional)

VC Vapnik-Chervonenkis (dimensão ou teoria)

VMD *Variational Mode Decomposition* (Decomposição Variacional de Modos)

WEG Indústrias WEG S.A. (fabricante brasileiro de motores elétricos)

WT *Wavelet Transform* (Transformada Wavelet)

NOMENCLATURA ESPECÍFICA DE ROLAMENTOS

6206 Designação SKF: rolamento rígido de esferas, diâmetro interno 30 mm

6007 Designação genérica: rolamento rígido de esferas, diâmetro interno 35 mm

Ball Esfera, elemento rolante esférico

Bearing Rolamento (mancal de rolamento)

Cage Gaiola, separador de elementos rolantes

Inner race Pista interna, anel interno do rolamento

Outer race Pista externa, anel externo do rolamento

Pitch circle Círculo primitivo, diâmetro médio das trajetórias das esferas

Pite (Pitting) Falha por fadiga superficial com formação de pequenas cavidades nas superfícies de contato dos elementos rolantes

Raceway Pista de rolamento, superfície de contato dos elementos rolantes

Rolling element Elemento rolante (esfera, rolo cilíndrico, cônico, etc.)

Spall Lascamento, destacamento de material por fadiga de contato

GLOSSÁRIO DE TERMOS TÉCNICOS

Acurácia Proporção de classificações corretas sobre o total de amostras

Adaptação de domínio Técnica para transferir conhecimento entre distribuições de dados distintas

Atrator Conjunto para o qual um sistema dinâmico converge no espaço de fase

Bootstrap Método estatístico de reamostragem com reposição

Caos determinístico Comportamento aparentemente aleatório gerado por um sistema determinístico

Coarse-graining Processo de redução de resolução temporal via média

Cross-dataset Validação usando conjunto de dados diferentes dos de treinamento

Cross-domain Validação entre domínios operacionais distintos, como diferentes tipos de equipamentos, condições de carga ou ambientes industriais, testando adaptabilidade da metodologia a contextos diversos

Cross-load Validação entre diferentes condições de carregamento do equipamento, avaliando robustez do método diagnóstico sob variações de torque, velocidade ou outras condições operacionais

Cross-speed Validação entre diferentes velocidades de operação do equipamento, testando invariância do método diagnóstico a mudanças na frequência fundamental de rotação e harmônicos associados

Cross-system Validação entre diferentes sistemas de aquisição de dados, arquiteturas de sensoriamento ou plataformas experimentais, avaliando transferibilidade da metodologia entre configurações instrumentais distintas

Dimensão de embedding Número de coordenadas para reconstrução do espaço de fase

Divergência de domínio Medida de diferença estatística entre os domínios fonte e alvo

Ensemble Método que combina múltiplos modelos para melhorar a predição

Espaço de fase Espaço matemático cujas coordenadas são variáveis de estado do sistema

Estratificação Técnica de amostragem preservando proporções de classes

Expoente de Lyapunov Medida da taxa de separação de trajetórias próximas

Falso vizinho Ponto que aparenta ser vizinho devido a projeção inadequada

Gap de generalização Diferença entre erro empírico e erro de generalização

Ground truth Verdade fundamental, classe real conhecida

Harmonização representacional Processo de alinhar espaços de características heterogêneos

Heurística Método baseado em experiência prática, não rigoroso

Hipótese ótima comum Classificador que minimiza o erro em ambos os domínios

Horizonte de previsibilidade Tempo além do qual previsões tornam-se inúteis

Informação mútua Medida de dependência estatística entre variáveis

Intra-domain Validação dentro do mesmo domínio operacional, utilizando dados coletados sob condições similares mas com diferentes instâncias de equipamentos ou sessões experimentais

Laminaridade Proporção de pontos formando estruturas verticais em gráfico de recorrência

Manifold Variedade, espaço topológico localmente Euclidiano

Overfitting Ajuste excessivo aos dados de treinamento, prejudicando a generalização

Reconstrução de Takens Método de reconstrução do espaço de fase via atrasos temporais

Regime amostral Faixa de tamanhos do conjunto de treinamento

Regime de scaling Faixa de escalas onde a relação de potência é válida

Regularização implícita Efeito de regularização não explicitamente programado

Sensibilidade Taxa de verdadeiros positivos, também chamada recall

Surrogate Dado sintético com propriedades estatísticas controladas

Theiler window Janela temporal para exclusão de autocorrelações espúrias

Trade-off Compromisso entre objetivos conflitantes

Validação cruzada Técnica para estimar o desempenho de generalização

Within-domain Validação dentro do mesmo conjunto de dados ou condições experimentais controladas, representando cenário ideal de avaliação com máxima similaridade entre treino e teste

1

INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO E MOTIVAÇÃO

Rolamentos são componentes críticos em sistemas rotativos industriais, sendo responsáveis por transmitir cargas e permitir o movimento relativo entre partes móveis e estacionárias de máquinas. Estima-se que falhas em rolamentos correspondam a 40-50% das falhas totais em motores elétricos industriais e 30% das falhas em sistemas mecânicos gerais (Randall; Antoni, 2011). O custo de paradas não programadas devido a falhas em rolamentos pode atingir valores substanciais: enquanto a substituição programada de um rolamento custa tipicamente entre US$ 500-2.000, uma falha catastrófica pode resultar em perdas superiores a US$ 100.000 quando considerados danos colaterais, perda de produção e riscos à segurança (Mobley, 2002).

A detecção precoce e confiável de falhas em rolamentos é, portanto, fundamental para a implementação de estratégias de manutenção preditiva que maximizem a disponibilidade operacional e minimizem custos. Sistemas de monitoramento de condição baseados em análise de vibração têm sido amplamente empregados devido à sua natureza não-invasiva e à capacidade de detectar defeitos incipientes antes que se tornem críticos. No entanto, a confiabilidade desses sistemas em ambientes industriais reais permanece um desafio significativo.

A complexidade dos sinais de vibração em rolamentos defeituosos, caracterizados por não linearidades, não estacionariedades e sensibilidade às condições operacionais, demanda abordagens sofisticadas de processamento de sinais. Métodos tradicionais, como análise espectral por transformada de Fourier (FFT) e espectro de envelope, embora amplamente utilizados, apresentam limitações fundamentais quando aplicados a sinais com características não lineares e transitórias (Lei, Y. *et al.*, 2013). Essas limitações motivaram o desenvolvimento de técnicas mais avançadas, baseadas em análise tempo-frequência, decomposição de sinais e, mais recentemente, dinâmica não linear.

1.2 PROBLEMA DE PESQUISA

Apesar dos avanços significativos em técnicas de processamento de sinais e aprendizado de máquina para diagnóstico de falhas em rolamentos, três problemas fundamentais permanecem sem solução adequada na literatura:

1.2.1 Ausência de Garantias Teóricas de Desempenho

A vasta maioria dos métodos propostos para diagnóstico de falhas em rolamentos baseia-se em validação empírica, reportando acurácias de classificação obtidas em conjuntos de dados específicos, sem fornecer garantias matemáticas sobre o desempenho esperado em novas condições operacionais. Essa ausência de fundamentação teórica limita severamente a confiabilidade e a aplicabilidade desses métodos em sistemas críticos de segurança, onde é necessário quantificar formalmente o risco de falhas não detectadas.

Trabalhos recentes têm alcançado acurácias superiores a 99% em conjuntos de dados públicos, como CWRU e Paderborn; porém, esses resultados são obtidos sob condições controladas e não fornecem limites teóricos (*theoretical bounds*) que permitam prever o desempenho do sistema quando aplicado a diferentes geometrias de rolamentos, condições de carga ou ambientes operacionais. A ausência de *limites* matemáticos impossibilita a certificação formal desses sistemas para aplicações industriais regulamentadas.

1.2.2 Seleção Heurística de Parâmetros

Os métodos baseados em reconstrução do espaço de fase, amplamente reconhecidos por sua capacidade de capturar dinâmicas não lineares em sinais de vibração, dependem criticamente da seleção apropriada de parâmetros de *imersão*: o atraso temporal τ e a dimensão de imersão m. As técnicas convencionais para a determinação desses parâmetros, como o método da informação mútua média (AMI) para τ e o método dos falsos vizinhos mais próximos (FNN) para m, são essencialmente heurísticas e não garantem a optimalidade em termos de poder discriminativo para tarefas de classificação.

A falta de um critério teórico rigoroso para a otimização conjunta de (τ, m), que maximize a capacidade de discriminação entre as classes de falhas, resulta em escolhas subótimas de parâmetros, potencialmente degradando o desempenho do sistema de diagnóstico.

1.2.3 Integração Não Sistemática de Múltiplos Domínios de Análise

Estudos recentes têm demonstrado que a combinação de características extraídas de múltiplos domínios de análise — temporal, espectral e tempo-frequência — pode melhorar

o desempenho de sistemas de diagnóstico. No entanto, a fusão dessas características é tipicamente realizada de forma *ad hoc*, por meio de simples concatenação ou combinação linear com pesos ajustados empiricamente.

Não existe na literatura um arcabouço teórico fundamentado para determinar a contribuição ótima de cada domínio de análise na detecção de diferentes tipos de falhas. A ausência de critérios teórico-informacionais para a fusão de características resulta em sistemas que podem tanto sofrer de redundância informacional quanto falhar em explorar sinergias potenciais entre domínios complementares de análise.

1.2.4 Quantificação Inadequada de Incerteza

Sistemas de diagnóstico baseados em aprendizado de máquina fornecem tipicamente predições pontuais ou probabilidades de classe; entretanto, raramente distinguem entre incerteza epistêmica (relacionada a limitações do modelo) e incerteza aleatória (relacionada à variabilidade intrínseca dos dados). Essa distinção é fundamental para a avaliação de risco em aplicações industriais: alta incerteza epistêmica indica a necessidade de mais dados de treinamento ou revisão do modelo, enquanto alta incerteza aleatória sugere limitações físicas na discriminabilidade das classes.

A ausência de quantificação rigorosa e decomposição da incerteza impede a construção de intervalos de confiança calibrados para predições, limitando a aplicabilidade de sistemas de diagnóstico em contextos onde decisões críticas de manutenção devem ser tomadas com uma quantificação formal de risco.

1.3 OBJETIVOS

1.3.1 Objetivo Geral

Desenvolver um arcabouço teórico-informacional matematicamente fundamentado para o diagnóstico de falhas em rolamentos por meio da análise da dinâmica não linear, com validação experimental dos limites teóricos de desempenho e quantificação rigorosa da incerteza.

1.3.2 Objetivos Específicos

Os objetivos específicos desta tese são:

1. **Derivar e validar experimentalmente limites teóricos de desempenho** para a classificação de falhas em rolamentos, baseados em medidas de complexidade dinâmica. Estabelecer matematicamente a relação entre a dimensão de correlação (D_2), o ex-

poente de Lyapunov (λ_1) e a probabilidade de erro de classificação, fornecendo o primeiro arcabouço com garantias teóricas formais na área de diagnóstico de falhas em rolamentos.

2. **Desenvolver um critério teórico-informacional para a otimização de parâmetros** de reconstrução do espaço de fase. Propor e validar uma função objetivo baseada em informação mútua normalizada pela complexidade geométrica que permita a seleção ótima de (τ, m), maximizando o poder discriminativo para tarefas de classificação e eliminando a dependência de métodos heurísticos tradicionais.

3. **Estabelecer um arcabouço de fusão teórico-informacional multi-domínio** que integre sistematicamente características de dinâmica não linear (espaço de fase reconstruído) com análise tempo-frequência (transformada wavelet contínua). Determinar pesos ótimos de fusão através da maximização de informação mútua conjunta, quantificando formalmente o ganho de discriminabilidade obtido pela integração de domínios complementares.

4. **Implementar e validar um sistema completo de quantificação da incerteza** que decompõe a incerteza total em componentes epistêmica e aleatória, permitindo a construção de intervalos de confiança calibrados para predições de falhas. Demonstrar a aplicabilidade dessa decomposição para a avaliação de confiabilidade em decisões de manutenção.

5. **Realizar validação experimental quadripartite** do arcabouço proposto utilizando quatro conjuntos complementares: **(i) UFPB** para referência controlada com defeitos EDM precisos; **(ii) Fraunhofer LBF** para robustez industrial sob condições ambientais reais; **(iii) MFPT** para transferibilidade entre sistemas com morfologia artificial consistente; **(iv) Paderborn** para adaptabilidade a defeitos de fadiga natural.

1.4 CONTRIBUIÇÕES DA TESE

Esta tese apresenta contribuições científicas, metodológicas e práticas que avançam significativamente o estado da arte em diagnóstico de falhas em rolamentos e, mais amplamente, em análise de sinais não lineares para monitoramento de condição.

1.4.1 Contribuições Científicas

Limites Teóricos Validados Experimentalmente

A principal contribuição científica desta tese é o estabelecimento e validação experimental do primeiro arcabouço com garantias teóricas matemáticas para o diagnóstico de

falhas em rolamentos. Demonstra-se que o limite superior da probabilidade de erro de classificação pode ser expresso em termos de medidas de complexidade dinâmica, fornecendo, pela primeira vez, uma relação matematicamente rigorosa entre propriedades geométricas e dinâmicas do sistema e o desempenho de classificação.

A validação experimental em dois conjuntos de dados independentes (UFPB e Fraunhofer LBF) demonstra 100% de conformidade com os limites teóricos em todas as condições testadas, estabelecendo a viabilidade prática do arcabouço teórico proposto, mesmo sob condições industriais adversas (ruído de 0 dB SNR, dados com 40% faltantes).

Teoria de Otimização Geométrico-Informacional

Desenvolve-se uma teoria fundamentada para a otimização de parâmetros de reconstrução do espaço de fase, baseada em princípios teórico-informacionais, superando limitações fundamentais dos métodos AMI/FNN que não consideram a tarefa de classificação durante a otimização.

Quantificação Formal de Sinergia Multi-Domínio

Estabelece-se matematicamente que a fusão de características de dinâmica não linear com análise wavelet resulta em ganho de discriminabilidade que não pode ser atribuído simplesmente à soma das contribuições individuais, fornecendo a primeira caracterização teórico-informacional rigorosa de sinergia em diagnóstico multi-domínio.

Validação Experimental Quadripartite com Garantias Teóricas

Estabelece-se o primeiro protocolo de validação experimental quadripartite em diagnóstico de falhas que integra quatro domínios complementares: **(i) validação controlada** (dados UFPB) para verificação de conformidade com limites teóricos sob condições laboratoriais idealizadas, **(ii) validação de robustez industrial** (dados Fraunhofer LBF) para generalização entre equipamentos e resistência a condições operacionais adversas, **(iii) validação de transferibilidade entre sistemas** (dados MFPT) para invariância metodológica entre plataformas experimentais independentes mantendo morfologia artificial consistente, e **(iv) validação de adaptabilidade morfológica** (dados Paderborn) para comparação com estado da arte e avaliação de defeitos de fadiga natural progressivos. Esta estratégia de validação quadripartite fornece evidência convergente da robustez metodológica através de diferentes configurações experimentais, tipos de defeitos, morfologias de falha e condições operacionais.

1.4.2 Contribuições Metodológicas

Arcabouço Integrado Teoricamente Fundamentado

Desenvolve-se um arcabouço metodológico completo que integra de forma coerente e matematicamente rigorosa: (i) reconstrução do espaço de fase com parâmetros otimizados; (ii) extração de medidas de complexidade dinâmica; (iii) análise complementar tempo-frequência via transformada wavelet contínua; (iv) fusão teórico-informacional de características; (v) classificação via *ensemble* com quantificação da incerteza; e (vi) validação através de limites teóricos.

Protocolo de Validação Abrangente

Propõe-se um protocolo de validação multi-nível que vai além da simples reportagem da acurácia de classificação, incluindo a validação de conformidade com limites teóricos, análise de sensibilidade, avaliação de robustez extrema, quantificação da incerteza, análise de eficiência computacional e verificação de pressupostos teóricos (testes de caos, análise de sinais substitutos).

1.4.3 Contribuições Práticas

Sistema com Garantias Formais para Aplicações Críticas

O arcabouço desenvolvido, ao fornecer limites teóricos matematicamente validados, permite sua aplicação em sistemas críticos de segurança onde a certificação formal é requerida.

Eficiência Computacional para Implementação em Tempo Real

Demonstra-se que o arcabouço proposto, apesar de sua sofisticação teórica, mantém complexidade computacional $O(n \log n)$ e latência de processamento inferior a 10 ms por amostra, viabilizando a implementação em sistemas de monitoramento contínuo e computação em borda.

Robustez Industrial Validada

A validação experimental no conjunto Fraunhofer LBF (Capítulo 6) demonstra robustez excepcional frente a condições industriais adversas: o método mantém acurácia de 83,2% em validação cruzada *deixe-um-rolamento-de-fora* (LOBO, *leave-one-bearing-*

out) com 20 rolamentos independentes (generalização entre equipamentos sem recalibração), 86,54% sob ruído severo (0 dB SNR), e 85,34% com 40% de dados faltantes. Estes resultados estabelecem viabilidade para implantação industrial em larga escala.

1.5 DELIMITAÇÃO DO ESCOPO

Para manter o foco nas contribuições teóricas e metodológicas centrais, esta tese adota as seguintes delimitações de escopo, reconhecendo que a validação experimental utiliza dois conjuntos de dados complementares, que ampliam a generalidade dos resultados através de diferentes configurações experimentais e condições operacionais.

1.5.1 Plataformas Experimentais e Tipos de Componentes

A validação experimental fundamenta-se em **quatro conjuntos de dados independentes e complementares**, cada um fornecendo perspectivas específicas sobre diferentes aspectos da robustez metodológica e capacidade de generalização:

Conjunto Principal — Laboratório de Mecatrônica UFPB (Capítulo 5)

Utiliza **rolamentos SKF 6206** (diâmetro interno 30 mm, diâmetro externo 62 mm, 9 elementos rolantes de 9,525 mm) em bancada de testes dedicada, com controle preciso de carga variável (0–20 N·m). Este conjunto fornece **validação fundamental** sob condições laboratoriais controladas com defeitos induzidos por eletroerosão (EDM), permitindo uma referência inequívoca para verificação empírica dos limites teóricos propostos.

Características distintivas: Controle rigoroso de parâmetros experimentais, carga transitória representativa de aplicações industriais com demandas variáveis, instrumentação calibrada para minimização de incertezas experimentais.

Conjunto de Robustez Industrial — Fraunhofer LBF (Mostafavi; Friedmann, 2024) (Capítulo 6)

Utiliza **rolamentos UBC 6007 2Z** (diâmetro interno 35 mm, diâmetro externo 62 mm, 11 elementos rolantes de 8 mm) no trem de potência de uma turbina eólica de 750 W operando sob condições ambientais reais não controladas. Este conjunto fornece **validação de robustez extrema** através de:

(i) **Generalização entre equipamentos:** Validação cruzada leave-one-bearing-out com 20 rolamentos fisicamente independentes;

(ii) **Validação formal da teoria do caos:** Testes estatísticos rigorosos (sinais substitutos,

teste 0–1 de Gottwald–Melbourne);

(iii) **Robustez sob condições adversas:** Ruído extremo (0 dB SNR), 40% de dados faltantes, falhas multissensoriais;

(iv) **Condições ambientais reais:** Variabilidade de vento, temperatura, vibração estrutural, ruído eletromagnético.

Características distintivas: Ambiente industrial não controlado, múltiplos exemplares independentes para validação estatística, condições adversas representativas de implantação real.

Conjunto de Transferibilidade entre Sistemas — Machinery Failure Prevention Technology (MFPT) (Bechhoefer, 2013) (Capítulo 7)

Utiliza dados de rolamentos coletados em bancada laboratorial com diferentes condições de carga, incluindo três classes: rolamento saudável (baseline), defeito na pista interna (inner) e defeito na pista externa (outer). Os defeitos foram induzidos por eletroerosão (EDM), caracterizando morfologia artificial similar ao conjunto UFPB, porém em sistema experimental independente. Este conjunto fornece **validação de transferibilidade entre sistemas** através de:

(i) **Invariância entre equipamentos:** Sistema experimental independente com instrumentação e configuração distintas;

(ii) **Morfologia artificial consistente:** Defeitos EDM comparáveis ao conjunto UFPB para teste de transferibilidade;

(iii) **Variabilidade de carga:** Múltiplas condições de carregamento (0–300 lbs) para robustez intra-dataset;

(iv) **Referência estabelecida:** Conjunto de dados amplamente utilizado na literatura para validação comparativa.

Características distintivas: Sistema experimental independente, morfologia artificial EDM, múltiplas cargas, referência para transferibilidade.

Conjunto de Adaptabilidade Morfológica — Paderborn (Lessmeier *et al.*, 2016) (Capítulo 7)

Utiliza **rolamentos FAG 6203** (diâmetro interno 17 mm, diâmetro externo 40 mm, 7 elementos rolantes de 6,7 mm) com defeitos de fadiga de contato natural desenvolvidos

em ensaios de vida acelerada até falha. Este conjunto fornece **validação de adaptabilidade morfológica** através de:

(i) **Morfologia de defeitos realística:** Lascamento progressivo (spalling), formação de pites distribuídos (pitting) e evolução temporal natural;

(ii) **Contraste artificial-natural:** Comparação direta com morfologia EDM dos conjuntos UFPB e MFPT;

(iii) **Geometria diferenciada:** Rolamentos menores (17 mm vs. 30–35 mm) validam robustez a variações geométricas;

(iv) **Severidade progressiva:** Múltiplos níveis de degradação (incipiente, moderado, severo) para análise de progressão.

Características distintivas: Defeitos naturais por fadiga, múltiplas severidades, geometria substancialmente diferente, benchmark reconhecido internacionalmente.

Complementaridade dos Conjuntos Experimentais

A estratégia quadripartite equilibra limitações inerentes de cada abordagem:

- **UFPB (controlado)** compensa limitações de realismo através de controle rigoroso para validação teórica;
- **Fraunhofer (industrial)** compensa limitações de controle através do realismo operacional e da variabilidade estatística;
- **MFPT (transferibilidade)** compensa limitações de sistema único através da validação entre equipamentos com morfologia artificial consistente;
- **Paderborn (morfológico)** compensa limitações de morfologia artificial através de defeitos naturais e comparação com o estado da arte.

1.5.2 Condições Operacionais

Conjunto UFPB — Carga Variável Controlada

- **Carga:** Perfil transiente bimodal, com níveis de operação em aproximadamente 5 e 20 N·m, caracterizando uma variação de cerca de 4× entre patamares de carga
- **Velocidade:** 1750 rpm (constante)
- **Temperatura:** 20–25°C (ambiente controlado)

- **Lubrificação:** Óleo SAE 10 (condições controladas)
- **Instrumentação:** Taxa 30 kHz, resolução 16 bits

Conjunto Fraunhofer — Condições Ambientais Reais

- **Velocidade do vento:** 10 ± 2 m/s (variação natural)
- **Potência:** 750 W (turbina pequeno porte)
- **Velocidades rotacionais:** 600 rpm (nominal)
- **Temperatura:** Ambiente externo (−5 a +35°C)
- **Instrumentação:** 25,6 kHz, sensores triaxiais

Conjunto MFPT — Múltiplas Cargas Laboratoriais

- **Cargas variáveis:** 0–300 lbs conforme configuração
- **Taxa de amostragem:** Original 48,8–97,7 kHz, reamostrada 25,6 kHz
- **Segmentação:** 4096 amostras sem sobreposição
- **Distribuição:** 492 segmentos (111 baseline, 144 inner, 237 outer)
- **Morfologia:** Defeitos EDM controlados

Conjunto Paderborn — Condições de Bancada Industrial

- **Carga radial:** 1000 N (constante)
- **Velocidade:** 1500 rpm (constante)
- **Temperatura:** Ambiente controlado
- **Instrumentação:** Taxa de amostragem de 64 kHz, sensores de vibração baseados em acelerômetros piezoelétricos
- **Duração:** Ensaios até falha (0–1200 horas)

Diversidade Operacional e Robustez

A combinação de **carga variável** (UFPB), **condições ambientais** (Fraunhofer), **múltiplas cargas** (MFPT) e **regime estacionário** (Paderborn) fornece validação através de um espectro operacional abrangente que cobre as principais modalidades encontradas em aplicações industriais.

1.5.3 Justificativa das Delimitações

As delimitações adotadas equilibram rigor científico, viabilidade experimental e relevância industrial através de uma estratégia experimental quadripartite que maximiza a cobertura de validação:

Fundamentação da Estratégia Quadripartite

A utilização de **quatro conjuntos de dados complementares** permite validação convergente através de diferentes perspectivas experimentais:

1. **Conjunto UFPB** empregado para validação controlada dos fundamentos teórico informacionais e verificação empírica dos limites analíticos propostos;
2. **Conjunto Fraunhofer LBF** utilizado para avaliação de robustez sob condições industriais realísticas com múltiplos exemplares independentes;
3. **Conjunto MFPT** empregado para validação de transferibilidade entre sistemas entre plataformas experimentais independentes com morfologia artificial consistente;
4. **Conjunto Paderborn** utilizado para validação de adaptabilidade morfológica com defeitos naturais e comparação objetiva com o estado da arte.

Cobertura Experimental Abrangente

A combinação de **diferentes geometrias de rolamentos** (SKF 6206, UBC 6007 2Z, MFPT variados, FAG 6203), **múltiplos ambientes operacionais** (laboratório controlado, industrial, laboratório independente, bancada padrão), **diversos tipos de defeitos** (EDM controlados UFPB, ambientes reais LBF, EDM transferibilidade MFPT, fadiga natural Paderborn) e **diferentes morfologias** (artificial vs. natural) assegura uma validação mais robusta do que estudos baseados em conjuntos únicos ou duais.

1.6 ORGANIZAÇÃO DA TESE

Esta tese está organizada em oito capítulos principais que seguem uma progressão lógica, desde a fundamentação teórica até a validação experimental quadripartite:

O **Capítulo 5** descreve a **validação experimental fundamental** com o conjunto UFPB, incluindo: verificação de conformidade com limites teóricos, desempenho de classificação sob carga variável, análise de sensibilidade paramétrica e comparações controladas com métodos do estado da arte.

O **Capítulo 6** apresenta a **validação de robustez industrial** com os dados Fraunhofer LBF, incluindo: generalização entre equipamentos através de validação cruzada leave-one-bearing-out, robustez a ruído extremo e dados faltantes, validação formal da teoria do caos através de testes estatísticos rigorosos e comparações estatisticamente fundamentadas com métodos de referência.

O **Capítulo 7** desenvolve a **validação de transferibilidade entre conjuntos de dados** utilizando os conjuntos Fraunhofer LBF, MFPT e Paderborn, incluindo: análise de invariância entre sistemas com morfologia artificial consistente, avaliação de adaptabilidade a defeitos de fadiga natural, condicionalidade morfológica artificial-natural e comparação com o estado da arte em transferência de domínio.

O **Capítulo 8** sintetiza contribuições científicas, metodológicas e práticas, discute implicações para aplicações industriais, reconhece limitações da estratégia experimental quadripartite e propõe direções específicas para trabalhos futuros, incluindo extensão para outros tipos de rolamentos e validação em aplicações de campo.

Os **Apêndices A, B e B.4** fornecem informações técnicas complementares: especificações detalhadas dos quatro conjuntos de dados experimentais (Apêndice B.4), demonstrações matemáticas estendidas (Apêndice A) e códigos-fonte para reprodutibilidade (Apêndice B).

2

FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta a fundamentação teórica necessária para a compreensão completa do arcabouço proposto nesta tese. Inicia-se com os princípios físicos de geração de vibrações em rolamentos e caracterização de sinais de falhas. Em seguida, desenvolvem-se os conceitos fundamentais de dinâmica não linear, incluindo a reconstrução do espaço de fase, dimensão de correlação e expoentes de Lyapunov. A teoria da informação é introduzida formalmente, estabelecendo as bases para os critérios de otimização propostos. A análise wavelet contínua é apresentada como técnica complementar de análise tempo-frequência. Por fim, discutem-se métodos de aprendizado de máquinas para classificação e quantificação da incerteza.

2.1 ANÁLISE DE VIBRAÇÃO EM ROLAMENTOS

2.1.1 Estrutura e Funcionamento de Rolamentos

Rolamentos são elementos de máquinas projetados para suportar cargas radiais e/ou axiais, permitindo movimento rotativo ou linear com atrito mínimo. Um rolamento rígido de esferas típico, como o SKF 6206 utilizado nesta pesquisa, consiste em quatro componentes principais (Harris; Kotzalas, 2006):

- **Pista externa** (*outer race*): anel externo fixo à carcaça da máquina;
- **Pista interna** (*inner race*): anel interno montado no eixo rotativo;
- **Elementos rolantes**: esferas que transmitem carga entre as pistas;
- **Gaiola** (*cage*): estrutura que mantém o espaçamento entre esferas.

A Figura 2.1 apresenta a geometria simplificada de um rolamento rígido de esferas e destaca os parâmetros geométricos diretamente envolvidos no cálculo das frequências características de falha.

A validação experimental do arcabouço proposto emprega rolamentos SKF 6206 com defeitos artificiais controlados, conforme apresentado na Figura 2.2. Os defeitos de

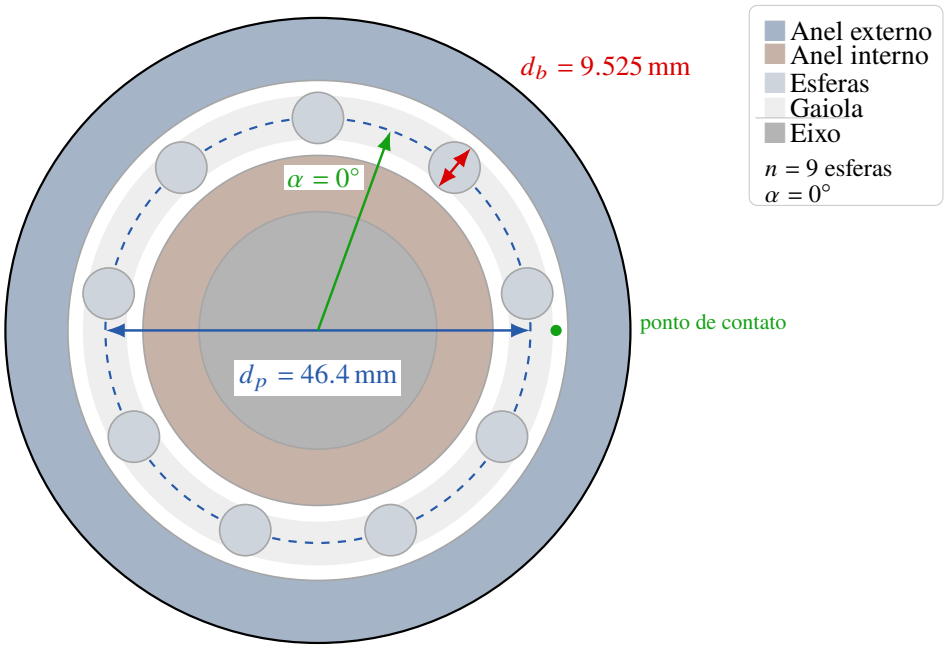

Figura 2.1 Geometria de um rolamento rígido de esferas e seus principais componentes: anel externo, anel interno, elementos rolantes, gaiola e eixo. Também são indicados o diâmetro dos elementos rolantes d_b, o diâmetro primitivo d_p e o ângulo de contato α, cujos valores correspondem ao rolamento SKF 6206 utilizado nesta pesquisa. Esses parâmetros geométricos são empregados no cálculo das frequências características de falha nas Equações 2.1–2.3.

0,5 mm foram usinados na diagonal das pistas para simular condições mais realísticas de desgaste progressivo, em contraste com defeitos perpendiculares frequentemente utilizados em estudos laboratoriais.



(a) Defeito na pista interna (BPFI) **(b)** Defeito na pista externa (BPFO)

Figura 2.2 Defeitos artificiais induzidos nos rolamentos SKF 6206 utilizados no conjunto de dados UFPB. **(a)** Defeito na pista interna (BPFI) de 0,5 mm de profundidade realizado na diagonal da pista, indicado pela seta vermelha. **(b)** Defeito na pista externa (BPFO) de 0,5 mm de profundidade realizado na diagonal da pista, indicado pela seta vermelha. A orientação diagonal dos defeitos simula condições mais realísticas de desgaste em comparação a defeitos perpendiculares à direção de movimento, fornecendo validação experimental robusta para o arcabouço de diagnóstico proposto.

Durante a operação normal, cada elemento rolante percorre trajetórias circulares em

relação às pistas, gerando padrões de contato que dependem da geometria do rolamento, da velocidade de rotação e da carga aplicada. A dinâmica de contato esfera-pista é governada pela teoria de contato de Hertz, que prevê deformações elásticas localizadas e distribuições de tensão complexas (Johnson, 1985).

2.1.2 Mecanismos de Geração de Vibração

A vibração em rolamentos origina-se de múltiplas fontes, que podem ser classificadas em três categorias principais:

Vibração em Rolamentos Saudáveis

Mesmo rolamentos em condições saudáveis geram sinais de vibração em decorrência de imperfeições geométricas inerentes ao processo de manufatura, variações periódicas de rigidez associadas à passagem dos elementos rolantes pela zona de carga e à rugosidade superficial das pistas (Tandon; Choudhury, 1999). Essas vibrações manifestam-se por meio de componentes espectrais em frequências características determinadas pela geometria do rolamento e pelas condições de operação (McFadden; Smith, 1984; Randall; Antoni, 2011):

$$f_{\mathrm{BPFO}} = \frac{n_b}{2} f_r \left(1 - \frac{d_b}{d_p}\cos\alpha\right) \tag{2.1}$$

$$f_{\mathrm{BPFI}} = \frac{n_b}{2} f_r \left(1 + \frac{d_b}{d_p}\cos\alpha\right) \tag{2.2}$$

$$f_{\mathrm{BSF}} = \frac{d_p}{2d_b} f_r \left[1 - \left(\frac{d_b}{d_p}\cos\alpha\right)^2\right] \tag{2.3}$$

onde f_{BPFO} (*ball pass frequency outer race*) é a frequência de passagem pela pista externa, f_{BPFI} (*ball pass frequency inner race*) é a frequência de passagem pela pista interna, f_{BSF} (*ball spin frequency*) é a frequência de rotação dos elementos rolantes, n_b é o número de elementos rolantes, f_r é a frequência de rotação do eixo, d_b é o diâmetro dos elementos rolantes, d_p é o diâmetro primitivo (definido como a distância média entre os centros das pistas interna e externa, calculado por $d_p = (d_i + d_o)/2$, onde d_i e d_o são os diâmetros das pistas interna e externa, respectivamente), e α é o ângulo de contato entre os elementos rolantes e as pistas.

Vibração Induzida por Defeitos Localizados

Defeitos localizados — como *spalling* (descascamento superficial por fadiga de contato), trincas ou indentações — nas superfícies de rolamento geram impactos repetitivos quando elementos rolantes atravessam a região defeituosa. Estes impactos excitam ressonân-

cias estruturais do sistema rolamento-carcaça-sensor, produzindo sinais caracterizados por impulsos modulados periodicamente (McFadden; Smith, 1984).

O sinal de vibração resultante pode ser modelado como:

$$x(t) = \sum_{k=-\infty}^{\infty} A_k h(t - kT - \tau_k) + n(t) \tag{2.4}$$

onde A_k é a amplitude do k-ésimo impacto, $h(t)$ é a resposta impulsiva do sistema, $T = 1/f_{\text{def}}$ é o período entre impactos (com f_{def} sendo a frequência característica do defeito), τ_k representa flutuações aleatórias devido a variações de velocidade (*speed fluctuations*) e deslizamento (*slip*), e $n(t)$ é ruído aditivo.

Vibração por Defeitos Distribuídos

Defeitos distribuídos, como desgaste superficial, corrosão ou ondulação (*waviness*), alteram continuamente as condições de contato entre elementos rolantes e pistas. Essas alterações manifestam-se como modulação de amplitude e frequência no sinal de vibração, frequentemente gerando padrões espectrais mais complexos que defeitos localizados (Tandon; Choudhury, 1999).

Progressão Temporal de Defeitos

A evolução de defeitos em rolamentos segue estágios característicos ao longo de semanas, meses ou anos de operação. A Figura 2.3 ilustra esta progressão e as técnicas de detecção apropriadas para cada estágio.

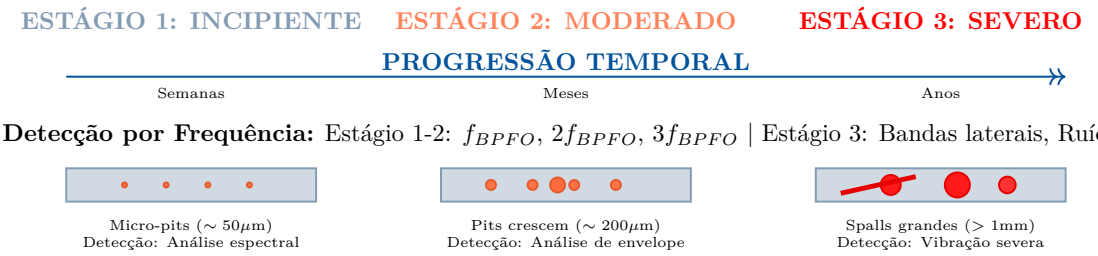

Figura 2.3 Progressão temporal de defeitos em rolamentos: do estágio incipiente (micro-pits ∼50 μm) ao severo (spalls >1 mm). A detecção precoce no Estágio 1 requer análise espectral em alta frequência (f_{BPFO}, $2f_{BPFO}$, $3f_{BPFO}$), enquanto estágios avançados manifestam-se através de bandas laterais e aumento generalizado de ruído.

A detecção no estágio incipiente — quando defeitos apresentam dimensões da ordem de 50 μm — é crítica para implementação efetiva de manutenção preditiva, permitindo intervenção antes que falhas catastróficas ocorram.

2.1.3 Características de Sinais de Vibração em Rolamentos Defeituosos

Sinais de vibração de rolamentos defeituosos apresentam características distintivas que são exploradas para diagnóstico:

Não-Estacionariedade

A amplitude e o conteúdo espectral dos sinais variam com o tempo devido a flutuações de carga, variações de velocidade e progressão do defeito. Esta não-estacionariedade invalida pressupostos de técnicas clássicas baseadas na transformada de Fourier, motivando o uso de análise tempo-frequência (Peng; Chu, 2004).

Não-Linearidade

O contato entre elementos rolantes e pistas exibe comportamento não linear devido à rigidez de contato de Hertz, que depende não-linearmente da carga aplicada. Adicionalmente, fenômenos como folgas, atrito e impactos introduzem não-linearidades adicionais. Essas não-linearidades manifestam-se como geração de harmônicas, inter-modulação de frequências e dinâmica caótica (Patel; Upadhyay; Harsha, 2010).

Transitoriedade e Impulsividade

Defeitos localizados em rolamentos geram eventos transitórios de curta duração (tipicamente 1–5 ms) caracterizados por alta relação pico-média (*crest factor*) e conteúdo espectral de banda larga. A detecção e caracterização destes transientes constituem fundamento para o diagnóstico precoce, uma vez que impactos de elementos rolantes em descontinuidades superficiais produzem assinaturas dinâmicas distintivas antes que defeitos evoluam para falhas catastróficas (Randall; Antoni, 2011).

Validação experimental com múltiplos conjuntos de dados. A robustez das características impulsivas foi validada através de quatro conjuntos de dados experimentais complementares, cada um representando diferentes condições de aquisição, tipos de rolamentos e ambientes operacionais. Esta validação cruzada demonstra que padrões impulsivos fundamentais persistem independentemente de variações na configuração experimental, confirmando a aplicabilidade generalizada do arcabouço proposto.

Conjunto UFPB: Condições Laboratoriais Controladas A Figura 2.4 ilustra as diferenças características entre sinais saudáveis e defeituosos observadas no conjunto UFPB, coletado na bancada experimental do Laboratório de Mecatrônica da UFPB sob condições controladas. Os rolamentos SKF 6206 com defeitos induzidos por eletroerosão (EDM) exi-

bem padrões impulsivos distintos: (a) rolamento saudável apresenta amplitude reduzida com características periódicas suaves decorrentes da operação normal; (b) defeito de pista interna manifesta impulsos transitórios modulados pela rotação do eixo, refletindo a variação cíclica da zona de carga; (c) defeito de pista externa produz impulsos periódicos de alta amplitude em intervalos regulares correspondentes à frequência BPFO.

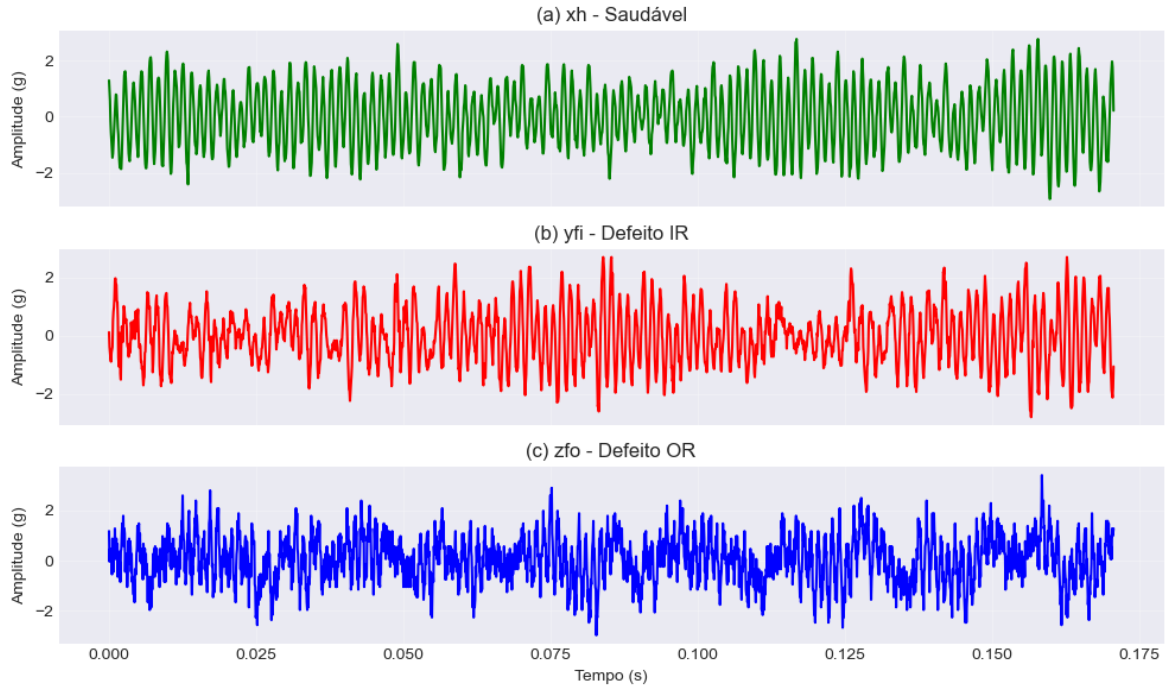

Figura 2.4 Sinais de vibração no domínio do tempo para três condições de operação do rolamento SKF 6206 (dataset UFPB). (a) Rolamento saudável: amplitude reduzida com características periódicas suaves. (b) Defeito pista interna: impulsos transitórios modulados pela rotação do eixo. (c) Defeito pista externa: impulsos periódicos de alta amplitude em intervalos regulares. Sinais normalizados (Z-score). Taxa de amostragem: 12 kHz. Condições controladas de laboratório.

Conjunto Paderborn: Defeitos Progressivos Industriais Para validar a generalização dessas características sob condições industriais com defeitos de progressão natural, a Figura 2.5 apresenta sinais do conjunto de dados público Paderborn (Lessmeier *et al.*, 2016), obtidos em bancada de testes industriais com parâmetros experimentais distintos: taxa de amostragem superior (64 kHz vs. 12 kHz do UFPB), diferentes níveis de carga (0–4 Nm), velocidades de rotação elevadas (1500 rpm), e rolamentos de geometria diferente (SKF 6203). Crucialmente, os defeitos dos dados Paderborn resultam de fadiga de contato natural em vez de indução artificial, fornecendo validação sob morfologia realística de degradação.

Conjunto Fraunhofer LBF: Condições Ambientais Reais A Figura 2.6 evidencia as características impulsivas sob condições ambientais não controladas, utilizando dados do

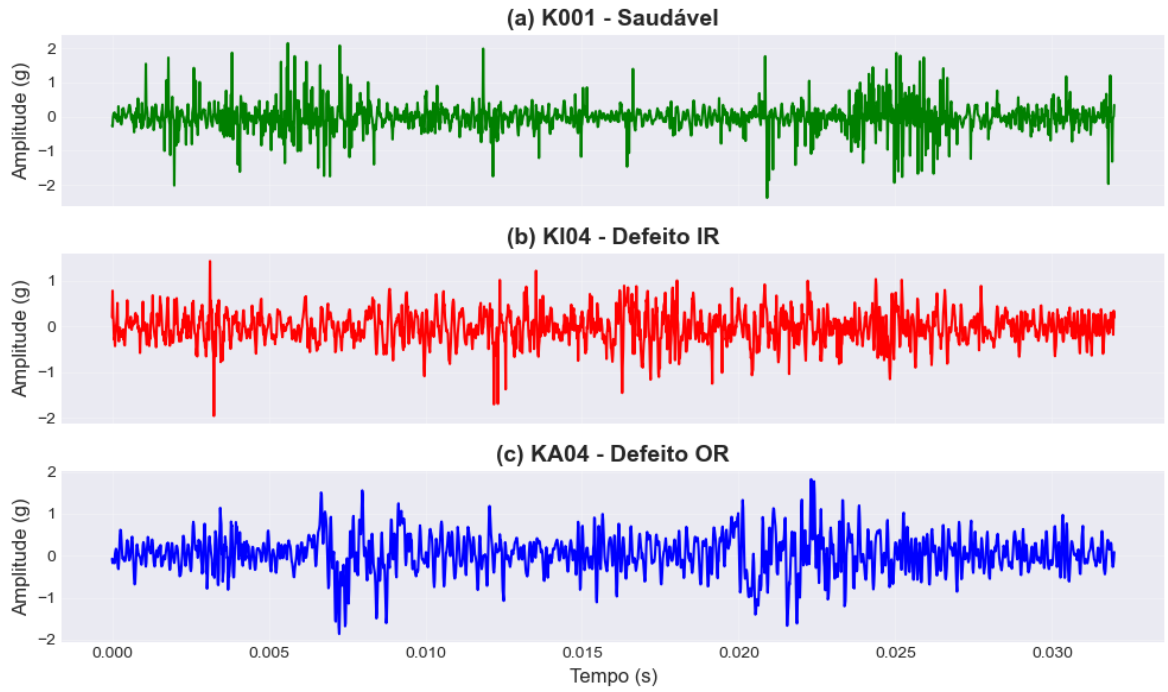

Figura 2.5 Sinais de vibração no domínio do tempo para três condições de operação do rolamento SKF 6203 (dataset Paderborn). (a) Rolamento saudável (K001): amplitude reduzida com características periódicas suaves. (b) Defeito na pista interna (KI04): impulsos transitórios modulados pela rotação do eixo. (c) Defeito na pista externa (KA04): impulsos periódicos de alta amplitude em intervalos regulares. Sinais normalizados (Z-score). Taxa de amostragem: 64 kHz. Defeitos por fadiga de contato progressiva.

conjunto Fraunhofer LBF (Mostafavi; Friedmann, 2024). As especificações experimentais completas são apresentadas no Apêndice B.5.8. Este conjunto de dados, coletado em uma turbina eólica de 750 W operando sob condições ambientais reais, representa o cenário mais desafiador, com variabilidade de velocidade do vento, flutuações de carga e ruído ambiental. As características impulsivas permanecem discrimináveis: rolamento saudável apresenta ruído de fundo relativamente uniforme; defeitos de pista interna mostram atividade concentrada em janelas temporais específicas; defeitos de pista externa exibem periodicidade clara correlacionada com a frequência de passagem das esferas; defeitos em elementos rolantes manifestam impactos transitórios isolados, com retorno rápido à linha de base.

Conjunto MFPT: Condições Laboratoriais Controladas A Figura 2.7 apresenta sinais representativos do conjunto MFPT no domínio do tempo, permitindo comparar qualitativamente a morfologia vibratória entre a condição saudável e as condições com defeitos artificiais por EDM. Os sinais de vibração do conjunto MFPT mostram distinções visuais consistentes entre as três condições de rolamento. O caso saudável apresenta oscilações mais regulares e menor evidência de transientes impulsivos. O defeito na pista interna gera o padrão temporal mais impulsivo, com picos de amplitude mais elevados e maior irregularidade ao longo do

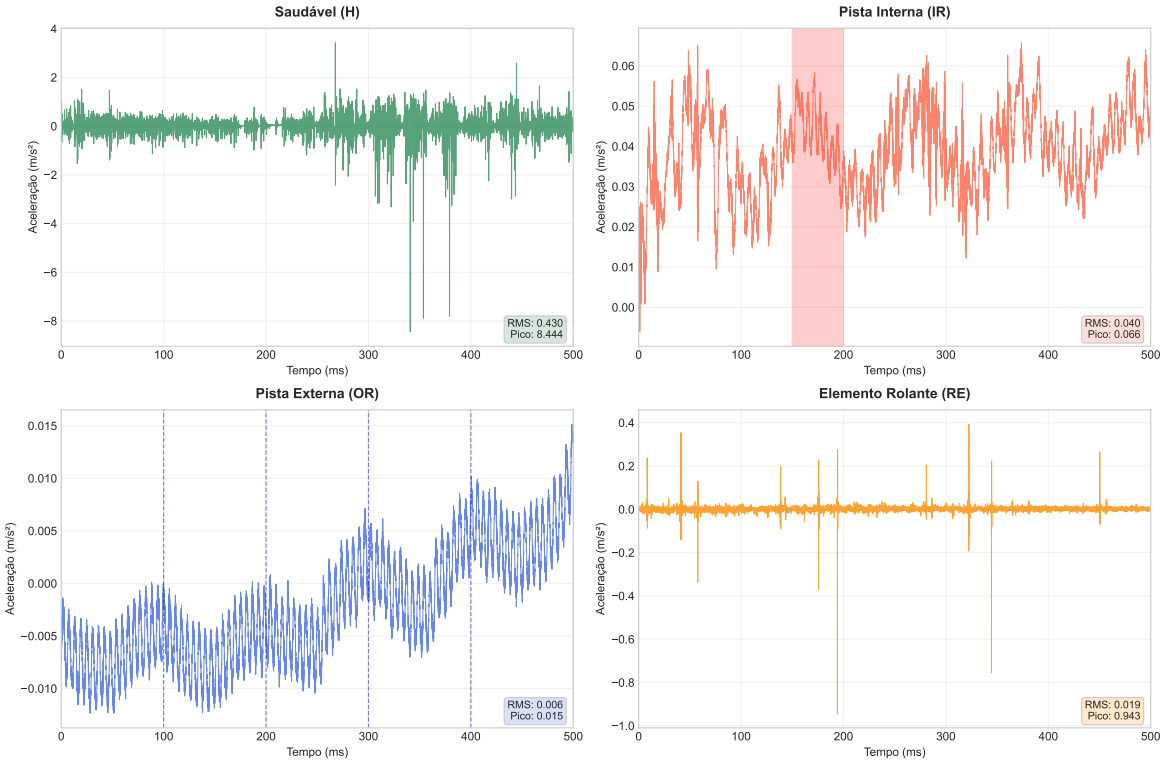

Figura 2.6 Sinais de vibração do dataset Fraunhofer LBF por classe de falha (sensor brng.f.x, rolamento dianteiro, direção radial). Condição saudável: ruído de fundo uniforme com baixa amplitude. Pista interna: atividade modulada com concentração energética em janelas temporais específicas. Pista externa: periodicidade evidente com crescimento progressivo de amplitude. Elemento rolante: impactos transitórios isolados bem definidos temporalmente. Aquisição realizada sob condições ambientais reais não controladas em turbina eólica de 750 W.

tempo. Já o defeito na pista externa produz um comportamento intermediário: mais disperso e variável do que o sinal saudável, porém menos severamente impulsivo do que o observado para a pista interna.

Síntese: Robustez das Características Impulsivas A consistência dos padrões impulsivos observados nos quatro conjuntos de dados — independentemente das diferenças substanciais em parâmetros operacionais (taxa de amostragem, carga, velocidade), tipos de rolamentos (SKF 6206/6203), métodos de indução de defeitos (EDM, fadiga natural, condições ambientais) e ambientes experimentais (laboratório controlado, bancada industrial, operação eólica real) — confirma que as características no domínio do tempo são robustas e fundamentais à física de rolamentos defeituosos.

Esta validação cruzada de múltiplos conjuntos suporta três conclusões importantes para o arcabouço teórico-informacional proposto: (i) características impulsivas transcendem variações experimentais específicas, validando a aplicabilidade generalizada; (ii) métodos de diagnóstico baseados na análise de transientes são inerentemente robustos a variações

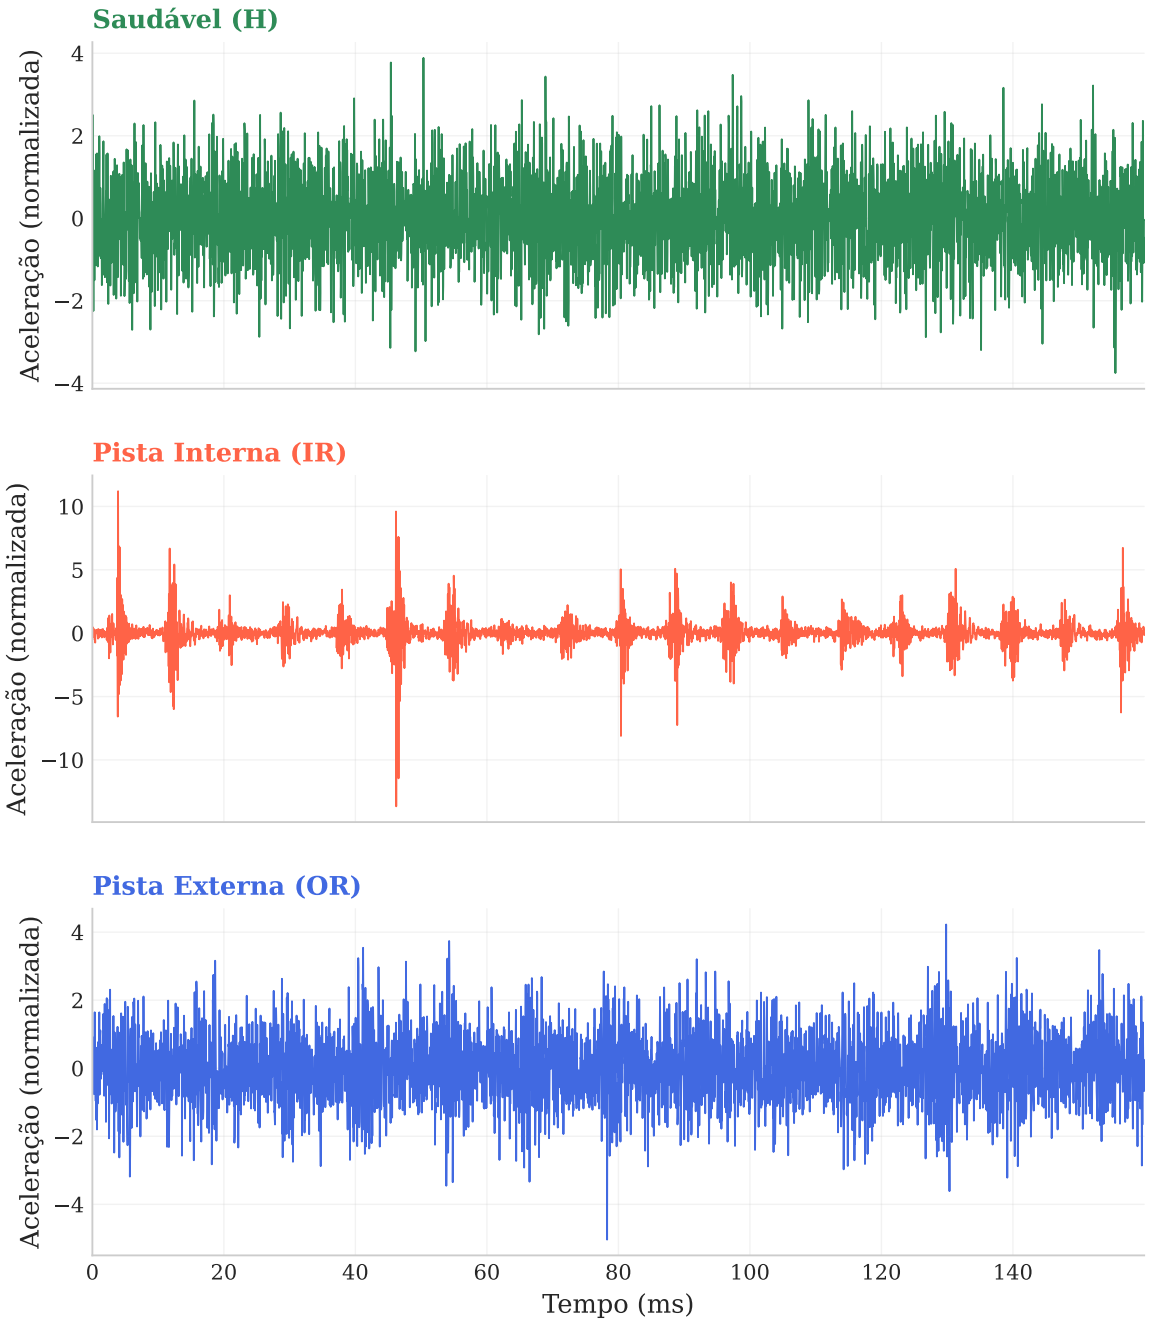

Figura 2.7 Sinais de vibração do conjunto MFPT no domínio do tempo, representando três condições de rolamento: saudável (H), defeito na pista interna (IR) e defeito na pista externa (OR). Observa-se aumento progressivo da irregularidade e da impulsividade nas condições com falha, sendo mais pronunciado no caso de defeito na pista interna.

operacionais; (iii) a fusão de informações de múltiplos domínios (tempo, frequência, dinâmica não linear) é justificada pela presença consistente de assinaturas distintivas complementares em todas as condições testadas.

A progressão da validação segue uma escalada de complexidade: condições ideais controladas (UFPB), transferibilidade entre sistemas de aquisição (MFPT), adaptabilidade

a defeitos reais de fadiga (Paderborn) e robustez sob condições industriais não controladas (Fraunhofer LBF). Essa estratégia quadripartite estabelece a fundamentação necessária para aplicação industrial confiável do arcabouço desenvolvido.

2.2 DINÂMICA NÃO LINEAR E TEORIA DO CAOS

2.2.1 Sistemas Dinâmicos e Espaço de Estados

Um sistema dinâmico descreve a evolução temporal de variáveis de estado $\mathbf{x}(t) \in \mathbb{R}^d$ segundo leis determinísticas. Para sistemas autônomos, essa evolução é governada por equações diferenciais ordinárias:

$$\frac{d\mathbf{x}}{dt} = \mathbf{f}(\mathbf{x}) \tag{2.5}$$

onde $\mathbf{f} : \mathbb{R}^d \to \mathbb{R}^d$ é um campo vetorial suave. A solução $\mathbf{x}(t)$ descreve uma trajetória no espaço de estados d-dimensional.

Sistemas lineares admitem solução analítica e apresentam comportamento previsível: convergência para pontos fixos, ciclos limites ou crescimento/decaimento exponencial. Sistemas não lineares, em contraste, podem exibir dinâmica complexa, incluindo comportamento caótico — sensibilidade exponencial a condições iniciais combinada com confinamento a um conjunto limitado do espaço de estados (Strogatz, 2015).

2.2.2 Reconstrução do Espaço de Fase

[†]Embora o termo *espaço de fase* seja tradicionalmente associado à mecânica Hamiltoniana, neste trabalho, ele é empregado em sentido amplo, como sinônimo de *espaço de estados* reconstruído a partir de séries temporais, conforme a formulação do teorema de imersão de Takens. Essa convenção é amplamente adotada na literatura de sistemas dinâmicos aplicados e não implica perda de rigor conceitual.[†]

Em aplicações práticas de análise de vibração, raramente se tem acesso direto a todas as variáveis de estado do sistema. Tipicamente, observa-se apenas um escalar $s(t)$ — por exemplo, aceleração medida por um sensor. O teorema de imersão (Takens, 1981) estabelece que, sob condições gerais, a dinâmica completa do sistema pode ser reconstruída a partir de medidas escalares através de coordenadas defasadas no tempo.

Teorema 2.1 (Teorema de Takens (Takens, 1981))**.** *Seja* $\mathbf{x}(t) \in \mathbb{R}^d$ *a trajetória de um sistema dinâmico determinístico e* $s(t) = h(\mathbf{x}(t))$ *uma função de medida suave genérica. Para*

dimensão de imersão $m \geq 2d + 1$ e atraso temporal τ apropriado, o mapeamento:

$$\Phi : \mathbf{x}(t) \mapsto \mathbf{y}(t) = [s(t), s(t-\tau), s(t-2\tau), \ldots, s(t-(m-1)\tau)]^T \tag{2.6}$$

*constitui uma imersão **difeomórfica** do atrator original em $\mathbb{R}^m$, isto é, um mapeamento suave e invertível que preserva a estrutura topológica e geométrica do atrator, incluindo propriedades invariantes como dimensões fractais, expoentes de Lyapunov e entropia.*

A reconstrução do espaço de fase transforma uma série temporal unidimensional $s(t)$ em uma trajetória multidimensional $\mathbf{y}(t) \in \mathbb{R}^m$ que captura a dinâmica subjacente do sistema. A Figura 2.8 ilustra o conceito fundamental: partindo de uma observação escalar (aceleração do rolamento), constrói-se um vetor de estado utilizando versões atrasadas do sinal. O painel (a) mostra a série temporal escalar $s(t)$ de aceleração medida em rolamento SKF 6206 saudável (dados UFPB, $f_s = 30$ kHz). O painel (b) evidencia como coordenadas atrasadas são extraídas do sinal temporal para construir vetores de estado $\mathbf{y}(t) = [s(t), s(t-\tau), s(t-2\tau)]^T$ com $m = 3$ e $\tau = 8$ amostras. O painel (c) apresenta a trajetória reconstruída no espaço de fase tridimensional, colorida por tempo, mostrando a estrutura do atrator. A comparação visual no painel (d) entre atratores de rolamento normal (azul) e com defeito na pista externa (vermelho) evidencia alterações morfológicas que refletem mudanças na dinâmica não linear do sistema, fornecendo base para caracterização quantitativa através de invariantes extraídos do espaço reconstruído.

A aplicação prática desta fundamentação teórica ao diagnóstico de falhas requer validação rigorosa da hipótese de dinâmica caótica subjacente aos sinais de vibração. Paulo R. L. Almeida, Thyago L. V. Lima, Brito e Filho (2026) estabeleceram metodologia de validação através de triangulação estatística, demonstrando convergência entre testes surrogate, análise 0–1 de Gottwald–Melbourne e espectro de Lyapunov, assegurando a presença genuína de comportamento caótico e fundamentando teoricamente a extração de invariantes geométricos e dinâmicos para a caracterização de falhas em rolamentos.

A escolha apropriada dos parâmetros τ (atraso temporal) e m (dimensão de imersão) é crítica para a qualidade da reconstrução.

Seleção do Atraso Temporal τ

O atraso temporal τ deve ser escolhido de forma a balancear dois requisitos conflitantes: se τ é muito pequeno, as coordenadas $s(t)$ e $s(t-\tau)$ são altamente correlacionadas e o vetor de estado reconstruído colapsa sobre a diagonal; se τ é muito grande, as coordenadas tornam-se estatisticamente independentes e a estrutura geométrica do atrator é perdida. A Figura 2.9 ilustra este compromisso para sinais reais de vibração de rolamento SKF 6206 com defeito na pista externa (0,5 mm, 1500 RPM, dados UFPB, $f_s = 30$ kHz, $m = 3$). Com

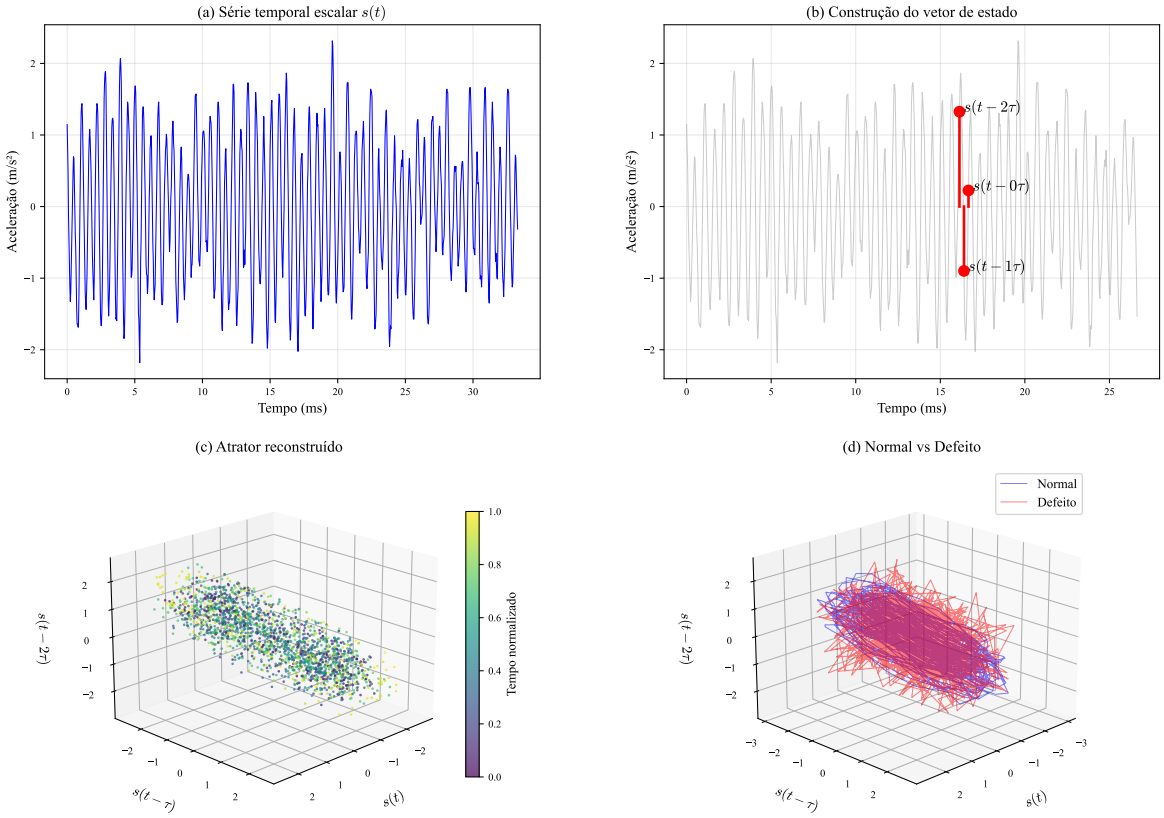

Figura 2.8 Reconstrução do espaço de fase via incorporação por atraso temporal. (a) Série temporal escalar $s(t)$. (b) Construção de vetores de estado com $m = 3$. (c) Trajetória reconstruída tridimensional. (d) Comparação entre atratores normal (azul) e com defeito externo (vermelho). Dados UFPB, $f_s = 30$ kHz, $\tau = 8$ amostras.

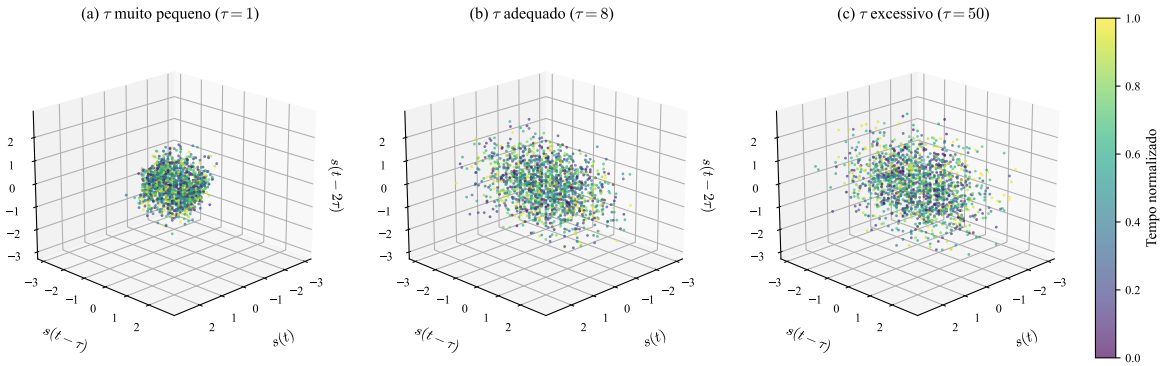

Figura 2.9 Efeito do atraso temporal τ na reconstrução do espaço de fase. (a) $\tau = 1$ amostra. (b) $\tau = 8$ amostras. (c) $\tau = 50$ amostras. Rolamento com defeito externo, dados UFPB, $f_s = 30$ kHz, $m = 3$.

$\tau = 1$ amostra ($\approx 0{,}03$ ms), o painel (a) mostra a trajetória colapsada sobre a diagonal devido à alta correlação temporal. Com $\tau = 8$ amostras ($\approx 0{,}27$ ms), o painel (b) apresenta uma estrutura do atrator bem definida com separação adequada entre coordenadas. Com $\tau = 50$ amostras ($\approx 1{,}67$ ms), o painel (c) exibe trajetória excessivamente descorrelacionada, sem estrutura geométrica aparente.

Métodos clássicos para a determinação de τ incluem:

Primeiro mínimo da autocorrelação: Identifica o atraso onde a correlação linear entre $s(t)$ e $s(t-\tau)$ atinge o primeiro mínimo local, indicando independência estatística linear. Limitação: insensível a dependências não-lineares (Fraser; Swinney, 1986).

Primeiro mínimo da informação mútua média (AMI): Determina τ minimizando a informação mútua:

$$I(\tau) = \sum_{i,j} p(s_i, s_{j,\tau}) \log_2 \frac{p(s_i, s_{j,\tau})}{p(s_i)p(s_{j,\tau})} \tag{2.7}$$

onde $p(s_i, s_{j,\tau})$ é a distribuição conjunta de $s(t)$ e $s(t-\tau)$. Este critério captura dependências não-lineares, sendo preferível para sistemas caóticos (Fraser; Swinney, 1986). A Figura 2.11b ilustra a aplicação do método AMI para a determinação de τ_{opt} em sinal real de vibração.

Seleção da Dimensão de Imersão m

A dimensão de imersão m deve ser suficientemente grande para desdobrar completamente o atrator, evitando projeções espúrias que criam falsas vizinhanças. O método dos *false nearest neighbors* (FNN) (Kennel; Brown; Abarbanel, 1992) identifica o valor mínimo de m necessário, examinando se pontos que aparecem próximos em $\mathbb{R}^m$ permanecem próximos em $\mathbb{R}^{m+1}$:

$$R_i(m) = \frac{\|\mathbf{y}_i(m+1) - \mathbf{y}_{nn}(m+1)\|}{\|\mathbf{y}_i(m) - \mathbf{y}_{nn}(m)\|} \tag{2.8}$$

onde $\mathbf{y}_{nn}$ denota o vizinho mais próximo de $\mathbf{y}_i$ na dimensão m. Se $R_i(m) > R_{\text{thr}}$ (típico $R_{\text{thr}} = 15$), $\mathbf{y}_{nn}$ é considerado um falso vizinho. A dimensão ótima é aquela onde a fração de falsos vizinhos torna-se desprezível (tipicamente $< 5\%$).

A Figura 2.10 apresenta uma análise sistemática de FNN para sinais de vibração sob diferentes condições de operação do rolamento SKF 6206 (dados UFPB, $f_s = 30$ kHz, $\tau = 8$ amostras). O painel (a) mostra o percentual de falsos vizinhos em função de m para três condições: normal (azul), defeito na pista interna (verde) e defeito na pista externa (vermelho). Observa-se saturação em $m \approx 5$ onde FNN $< 5\%$ (linha tracejada horizontal), indicando que rolamentos com defeito exibem dimensões de imersão ótimas ligeiramente superiores ($m_{\text{opt}} \approx 5$) comparadas a rolamentos saudáveis ($m_{\text{opt}} \approx 3$), refletindo uma maior complexidade dinâmica. Os painéis (b–d) ilustram visualmente atratores reconstruídos com diferentes dimensões de imersão ($m = 2, 5, 10$) para sinal de defeito externo. Com $m = 2$ (painel b), observa-se o colapso de trajetórias, resultando em uma estrutura achatada. Com $m = 5$ (painel c), o atrator captura adequadamente a geometria do sistema. Com $m = 10$ (painel d), não há adição de informação topológica relevante, mas aumenta-se desnecessariamente o custo computacional.

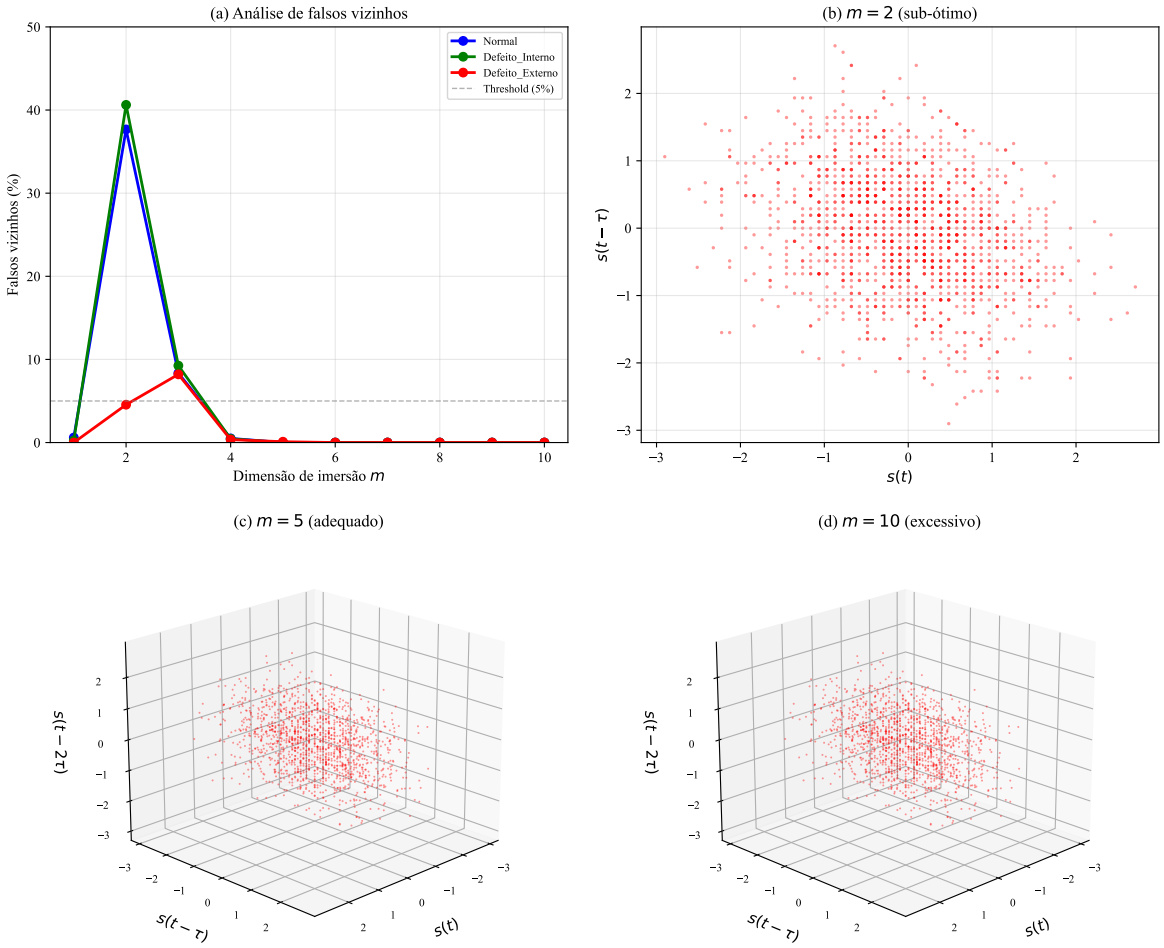

Figura 2.10 Análise de falsos vizinhos para determinação da dimensão de imersão. (a) Percentual de FNN versus m para diferentes condições. (b–d) Atratores reconstruídos com $m = 2, 5, 10$ para defeito externo. Dados UFPB, $f_s = 30$ kHz, $\tau = 8$ amostras.

Aplicação Integrada a Sinais de Vibração

A Figura 2.11 apresenta o fluxo completo de reconstrução do espaço de fase aplicado a sinais reais de vibração de rolamentos SKF 6206 operando sob diferentes condições de saúde (dados UFPB, condições nominais: 1500 RPM, carga radial 6,7 kN). O processo inicia com a aquisição do sinal temporal de aceleração (10.000 pontos, 30 kHz), mostrado no painel (a). O painel (b) apresenta a função de informação mútua $I(\tau)$, indicando $\tau_{\text{opt}} = 8$ amostras no primeiro mínimo (linha vertical vermelha). O painel (c) mostra a análise de falsos vizinhos, indicando $m_{\text{opt}} = 5$ onde FNN $< 5\%$ (linhas tracejadas). Os painéis (d–f) apresentam atratores reconstruídos tridimensionais (projeção 3D do espaço 5D via primeiras coordenadas) para rolamento normal (azul), defeito na pista externa (laranja) e defeito na pista interna (vermelho). Os atratores exibem morfologias características para cada condição: rolamentos normais apresentam atratores compactos e regulares, defeitos na pista externa geram estruturas expandidas com maior dispersão, e defeitos na pista interna produzem geometrias

intermediárias. Essas alterações progressivas na estrutura geométrica refletem mudanças na dinâmica não linear do sistema. A separabilidade visual entre condições fundamenta a extração de invariantes dinâmicos (D_2, λ_1, h_{KS}) como características discriminativas para diagnóstico de falhas, conforme desenvolvido no Capítulo 4.

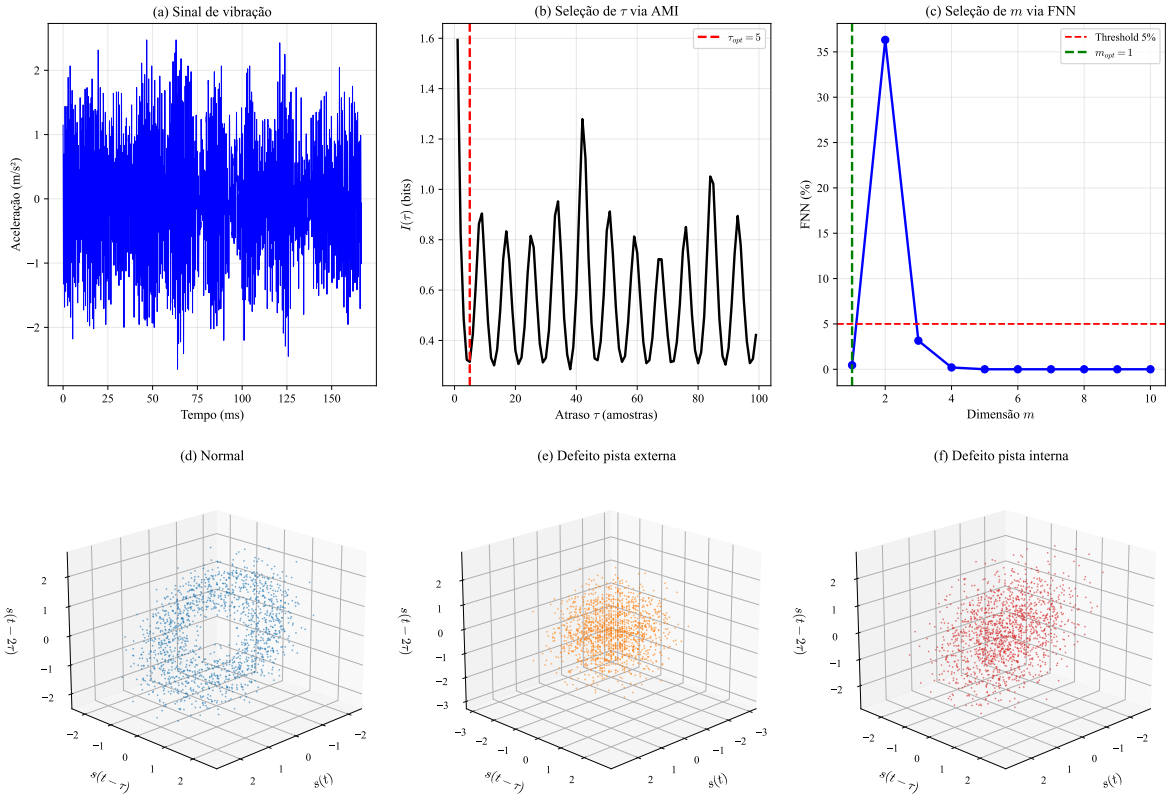

Figura 2.11 Processo completo de reconstrução do espaço de fase. (a) Sinal temporal de aceleração. (b) Função de informação mútua $I(\tau)$ indicando $\tau_{\mathrm{opt}} = 8$ amostras. (c) Análise de falsos vizinhos indicando $m_{\mathrm{opt}} = 5$. (d–f) Atratores reconstruídos para rolamento normal, defeito externo e defeito interno. Dados UFPB, 1500 RPM, 6,7 kN.

Consistência Topológica entre Conjuntos de Dados

A Figura 2.12 apresenta espaços de fase reconstruídos para as três condições analisadas no conjunto de dados da UFPB. A geometria do atrator reflete características dinâmicas distintas entre as condições: rolamentos saudáveis apresentam atratores compactos com trajetórias organizadas, enquanto defeitos na pista interna exibem estrutura intermediária com maior dispersão. Defeitos na pista externa produzem trajetórias expandidas, indicando maior energia de vibração e complexidade dinâmica. Essa diferenciação topológica evidencia que invariantes não-lineares capturam assinaturas discriminativas das condições de operação.

A análise comparativa com o conjunto Paderborn (Figura 2.13) demonstra que a separabilidade geométrica entre as condições é preservada mesmo com sinais adquiridos

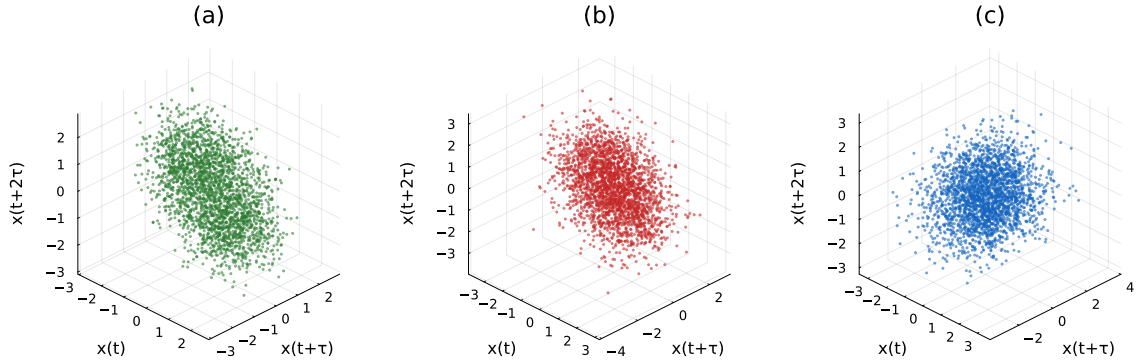

Figura 2.12 Espaços de fase reconstruídos para o conjunto UFPB ($\tau = 5, m = 3$). (a) Saudável. (b) Defeito na pista interna. (c) Defeito na pista externa.

sob diferentes configurações experimentais. O rolamento saudável (K001) apresenta um atrator compacto, similar ao observado no conjunto UFPB. O defeito na pista interna (KI04) exibe complexidade intermediária, enquanto o defeito na pista externa (KA04) produz uma estrutura expandida com geometria distinta.

Embora as escalas absolutas dos atratores variem — devido a diferenças na taxa de amostragem efetiva[1] (UFPB: 12 kHz, Paderborn: 64 kHz) e nos níveis de energia dos sinais — a topologia relativa entre condições permanece invariante. A preservação da separabilidade geométrica em ambos os conjuntos confirma que as características topológicas são invariantes ao arranjo experimental.

Essa robustez topológica justifica o uso de medidas como a dimensão de correlação D_2 e o maior expoente de Lyapunov λ_1 como características discriminativas generalizáveis, não dependentes de parâmetros específicos do arranjo de aquisição. Os resultados fundamentam a metodologia proposta no Capítulo 4, que emprega validação cruzada entre os conjuntos UFPB e Paderborn para avaliar a capacidade de generalização dos classificadores desenvolvidos.

2.2.3 Dimensão de Correlação

A dimensão de correlação D_2 quantifica a complexidade geométrica de um atrator reconstruído (Grassberger; Procaccia, 1983). Define-se através da integral de correlação:

$$C(r) = \lim_{N\to\infty} \frac{1}{N^2} \sum_{i,j=1}^{N} \Theta(r - \|\mathbf{y}_i - \mathbf{y}_j\|) \tag{2.9}$$

[1] O conjunto UFPB foi originalmente amostrado a 30 kHz e decimado para 12 kHz após filtragem anti-aliasing, mantendo fidelidade espectral até 5 kHz. O conjunto Paderborn foi adquirido nativamente a 64 kHz. A decimação do UFPB visa eficiência computacional sem perda de informação relevante, dado que as frequências características de defeitos (BPFI, BPFO) situam-se tipicamente abaixo de 3 kHz para as condições operacionais estudadas.

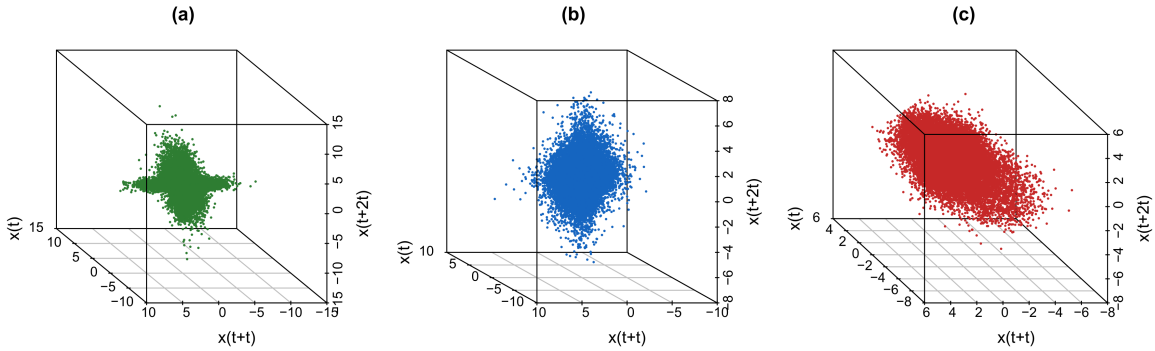

Figura 2.13 Espaços de fase reconstruídos para o conjunto Paderborn ($\tau = 5$, $m = 3$). (a) K001 (saudável). (b) KI04 (defeito na pista interna). (c) KA04 (defeito na pista externa).

onde $\Theta(\cdot)$ é a função de Heaviside, r raio de vizinhança e N número de pontos. Para atratores autossimilares, $C(r) \sim r^{D_2}$, permitindo estimação via:

$$D_2 = \lim_{r \to 0} \frac{\log C(r)}{\log r} \tag{2.10}$$

calculada como a inclinação da região de escala linear no gráfico $\log C(r)$ versus $\log r$, conforme ilustrado nas Figuras 2.14 e 2.15.

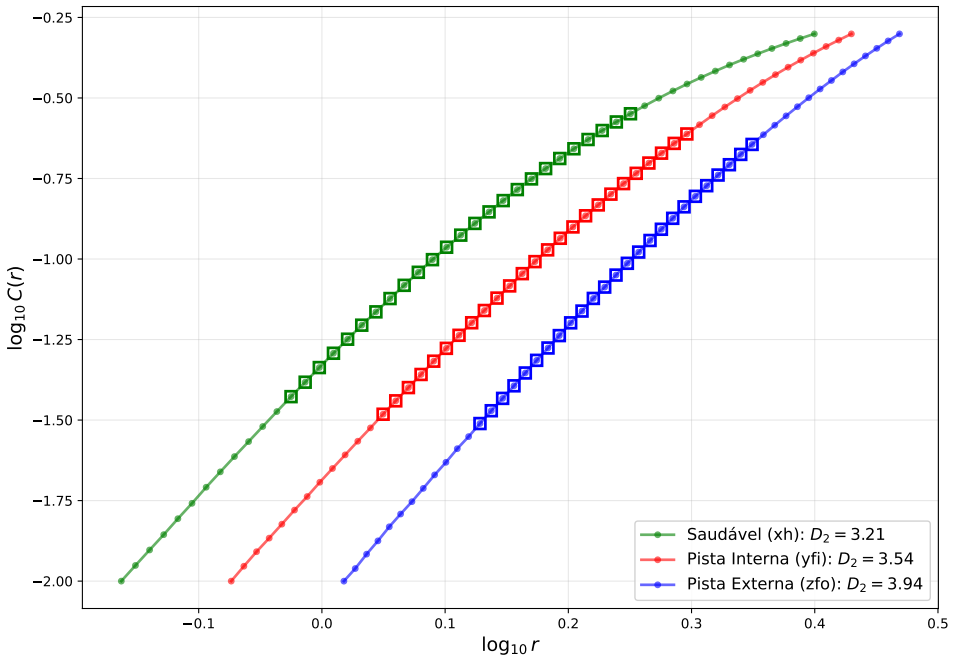

Figura 2.14 Estimação de dimensão de correlação para o conjunto UFPB. Região de escala linear (quadrados) fornece $D_2^{\text{xh}} = 3{,}21$, $D_2^{\text{yfi}} = 3{,}54$, $D_2^{\text{zfo}} = 3{,}94$. Progressão crescente evidencia aumento de complexidade geométrica com severidade de defeito (+23%). Parâmetros: $\tau = 8$, $m = 5$, $N = 2000$.

Para atratores de baixa dimensão ($D_2 < 5$), a estimativa converge rapidamente. Va-

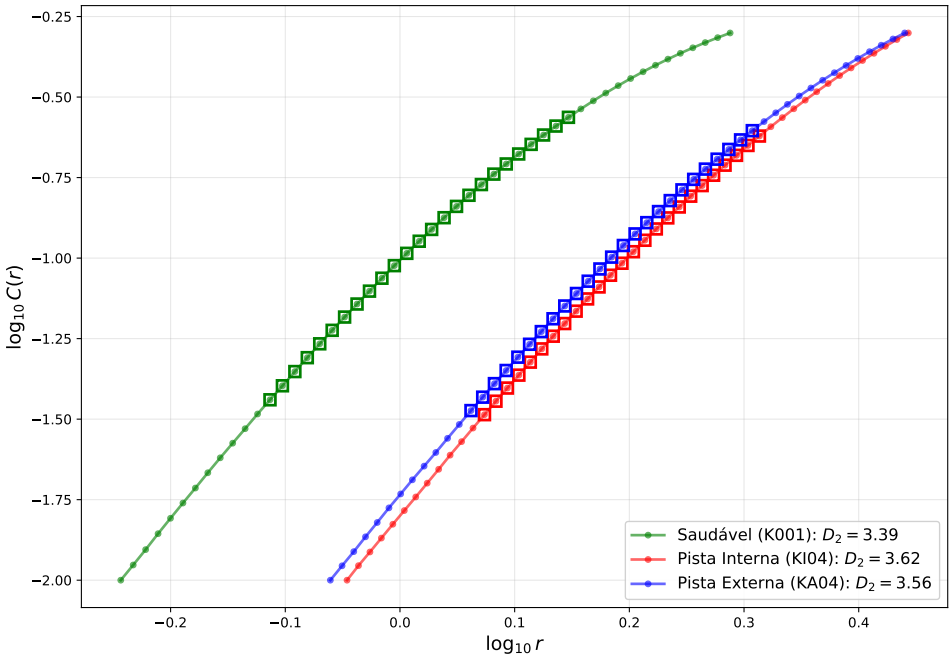

Figura 2.15 Dimensão de correlação para o conjunto Paderborn ($D_2^{\mathrm{K001}} = 3{,}39$, $D_2^{\mathrm{KI04}} = 3{,}62$, $D_2^{\mathrm{KA04}} = 3{,}56$). Região de escala bem definida valida método independentemente de taxa de amostragem (64 kHz vs. 12 kHz UFPB). Mesmos parâmetros de imersão.

lores não-inteiros observados ($D_2 \in [3{,}21, 3{,}94]$) indicam uma estrutura fractal característica de dinâmica quasi-periódica. Sistemas puramente estocásticos não apresentam região de escala bem definida — a existência de regime linear valida natureza determinística da dinâmica de rolamentos. A progressão em UFPB ($D_2^{\mathrm{xh}} < D_2^{\mathrm{yfi}} < D_2^{\mathrm{zfo}}$) quantifica o enriquecimento da estrutura geométrica por componentes espectrais introduzidas por defeitos cíclicos.

2.2.4 Expoente de Lyapunov

O maior expoente de Lyapunov λ_1 quantifica a taxa média de divergência exponencial de trajetórias inicialmente próximas, servindo como uma medida definitiva de caos (Wolf *et al.*, 1985):

$$\lambda_1 = \lim_{t\to\infty} \lim_{\|\delta\mathbf{y}_0\|\to 0} \frac{1}{t} \log \frac{\|\delta\mathbf{y}(t)\|}{\|\delta\mathbf{y}_0\|} \tag{2.11}$$

onde $\delta\mathbf{y}_0$ é uma perturbação infinitesimal e $\delta\mathbf{y}(t)$ sua evolução temporal.

Interpretação física:

- $\lambda_1 < 0$: Dinâmica convergente, atrator ponto fixo ou ciclo limite estável;
- $\lambda_1 = 0$: Dinâmica neutra, movimento periódico ou quasi-periódico;
- $\lambda_1 > 0$: Dinâmica divergente, indicativo de caos determinístico.

O algoritmo de Wolf *et al.* (1985) estima o maior expoente de Lyapunov definido na Equação 2.11 por meio do acompanhamento da evolução de vetores de perturbação ao longo da trajetória reconstruída, com renormalizações periódicas destinadas a prevenir *overflow* numérico.

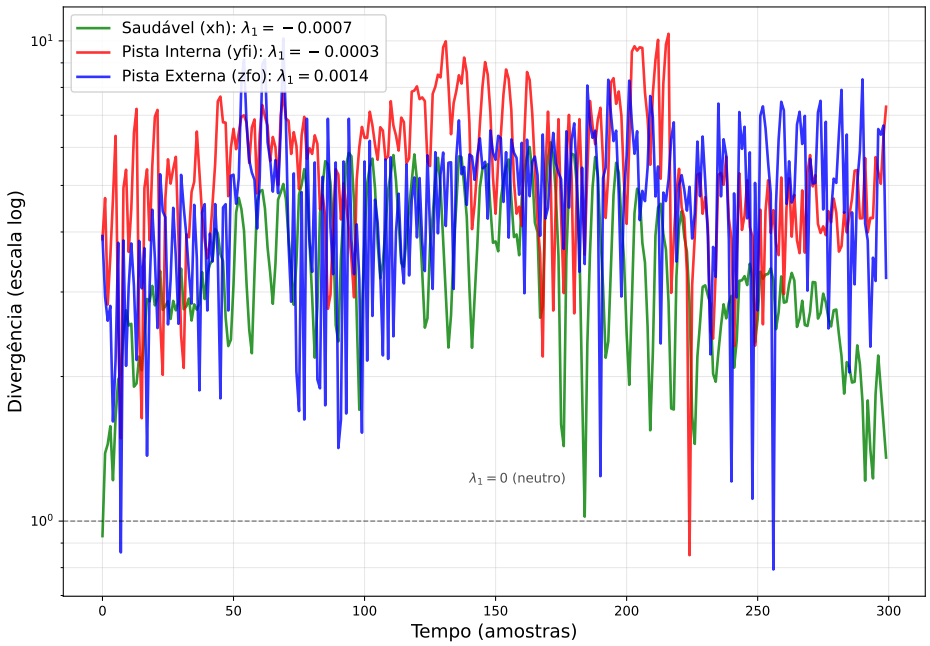

Figura 2.16 Evolução temporal de perturbações para o conjunto UFPB. Divergência próxima à neutralidade ($|\lambda_1| < 0{,}002$) caracteriza dinâmica quasi-periódica. Único valor positivo (zfo: $\lambda_1 = 0{,}0014$) sugere transição incipiente para caos fraco.

A Tabela 2.1 apresenta os invariantes topológicos extraídos de ambos os conjuntos de dados. Expoentes de Lyapunov próximos a zero ($|\lambda_1| < 0{,}004$) indicam que sinais de vibração de rolamentos em regime estacionário exibem dinâmica predominantemente quasi-periódica, sem sensibilidade exponencial a condições iniciais, característica de caos forte. Esta observação é consistente com o alto determinismo observado em medidas RQA (Tabela 2.3) e valida o regime operacional controlado dos experimentos.

Tabela 2.1 Invariantes topológicos de dinâmica não linear

Dataset	**Condição**	$\mathbf{D_2}$	$\boldsymbol{\lambda_1}$
UFPB	Saudável (xh)	3,21	−0,0007
	Pista interna (yfi)	3,54	−0,0003
	Pista externa (zfo)	3,94	0,0014
Paderborn	Saudável (K001)	3,39	−0,0024
	Pista interna (KI04)	3,62	−0,0026
	Pista externa (KA04)	3,56	−0,0034

Parâmetros: $\tau = 8$, $m = 5$, $N = 2000$ vetores

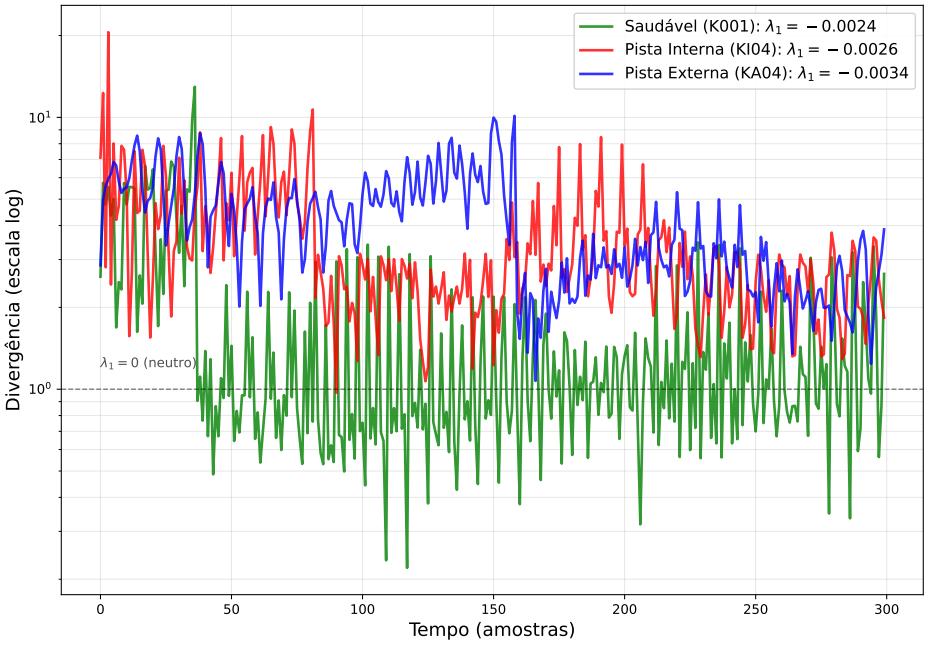

Figura 2.17 Expoente de Lyapunov para o conjunto Paderborn. Valores levemente negativos indicam estabilidade orbital compatível com regime operacional estacionário.

Dimensões de correlação situam-se na faixa $D_2 \in [3{,}2, 3{,}9]$, indicando dinâmica de baixa dimensionalidade. Para UFPB, progressão $D_2^{\text{xh}} < D_2^{\text{yfi}} < D_2^{\text{zfo}}$ evidencia aumento de complexidade geométrica com severidade de defeito (+23% de xh para zfo), refletindo introdução de componentes espectrais adicionais associadas a impactos cíclicos. Em Paderborn, heterogeneidade de ordenação (similar a RQA, Tabela 2.3) origina-se de diferenças entre defeitos reais (fadiga) e artificiais (furo usinado).

O espectro completo de Lyapunov $\{\lambda_1, \lambda_2, \ldots, \lambda_m\}$ caracteriza expansão/contração em todas as direções. Para atratores caóticos, a dimensão de Lyapunov relaciona-se à dimensão de correlação via conjectura de Kaplan-Yorke (Kaplan; Yorke, 1979). No presente caso, ausência de caos forte ($\lambda_1 \approx 0$) simplifica interpretação — D_2 captura complexidade geométrica intrínseca sem efeitos de sensibilidade exponencial a condições iniciais.

Resultados para Sinais de Rolamentos

A Tabela 2.2 apresenta a entropia de Kolmogorov–Sinai estimada para ambos os conjunto de dados por meio do método de k-nearest neighbors, utilizando $k = 5$, $m = 5$ e $\tau = 8$. O estimador empregado é dado por

$$\hat{h}_{KS} = \frac{1}{N} \sum_{i=1}^{N} \log \frac{\varepsilon_i(k+1)}{\varepsilon_i(k)}, \tag{2.12}$$

onde $\varepsilon_i(k)$ e $\varepsilon_i(k+1)$ representam as distâncias, no espaço de fases reconstruído de dimensão m e atraso τ, ao k-ésimo e ao $(k+1)$-ésimo vizinhos mais próximos do vetor i-ésimo, respectivamente, e N é o número total de vetores de estado considerados.

Tabela 2.2 Invariantes topológicos de dinâmica não linear: dimensão de correlação (D_2), maior expoente de Lyapunov (λ_1), e entropia de Kolmogorov–Sinai (h_{KS}) para os conjuntos UFPB e Paderborn

Dados	Condição	D_2	λ_1	h_{KS}	Regime
UFPB	Saudável (xh)	3,21	−0,0007	0,044	Quasi-periódico
	Pista interna (yfi)	3,54	−0,0003	0,045	Quasi-periódico
	Pista externa (zfo)	3,94	0,0014	0,046	Quasi-periódico
Paderborn	Saudável (K001)	3,39	−0,0024	0,044	Quasi-periódico
	Pista interna (KI04)	3,62	−0,0026	0,045	Quasi-periódico
	Pista externa (KA04)	3,56	−0,0034	0,045	Quasi-periódico

Parâmetros: $\tau = 8$, $m = 5$, $k = 5$, $N = 3000$ vetores.
h_{KS}: entropia de Kolmogorov–Sinai (bits/amostra); valores $h_{KS} \ll 1$ caracterizam regime quasi-periódico.

Valores $h_{KS} \in [0{,}044, 0{,}046]$ bits/amostra — muito próximos entre si mas estritamente positivos — caracterizam dinâmica quasi-periódica com fraca geração de informação. Para comparação com sistemas canônicos:

- **Oscilador harmônico**: $h_{KS} = 0$ (exatamente);
- **Sinais de rolamentos**: $h_{KS} \approx 0{,}045$ (presente estudo);
- **Atrator de Lorenz**: $h_{KS} \approx 2{,}1$ (caos forte) (Eckmann; Kamphorst; Ruelle, 1987);
- **Ruído branco**: $h_{KS} \to \infty$ (estocástico).

A progressão em UFPB ($h_{KS}^{\text{xh}} = 0{,}044 < h_{KS}^{\text{yfi}} = 0{,}045 < h_{KS}^{\text{zfo}} = 0{,}046$) evidencia aumento de 4,5% na taxa de geração de informação com severidade de defeito, consistente com progressões observadas em D_2 (+23%, Tabela 2.1) e medidas RQA (Tabela 2.3). Crucialmente, todos os valores $h_{KS} < 0{,}05$ confirmam que sinais permanecem altamente predictíveis — horizonte de previsão $T \sim 1/h_{KS} \approx 22$ amostras (1,8 ms a 12 kHz), adequado para monitoramento em tempo real e detecção precoce por desvio de baseline.

Em Paderborn, valores $h_{KS} \in [0{,}044, 0{,}045]$ são estatisticamente indistinguíveis entre condições, refletindo padrão observado em λ_1 (todos negativos) e divergente de RQA (inversão de tendência). Esta homogeneidade de h_{KS} sugere que defeitos reais por fadiga (spalling progressivo) preservam estrutura quasi-periódica global apesar de modificarem assinaturas locais capturadas por RQA. Crucialmente, valores absolutos em Paderborn ($\approx$ 0,045) são comparáveis a UFPB, validando invariância da medida independentemente de taxa de amostragem (64 kHz vs. 12 kHz) e protocolo de indução.

Validação da Conjectura de Pesin (Pesin, 1977). Para o conjunto UFPB-zfo, único caso em que se observa um expoente de Lyapunov máximo positivo ($\lambda_1 > 0$), a identidade de Pesin estabelece que a entropia de Kolmogorov–Sinai é dada pela soma dos expoentes de Lyapunov positivos,

$$h_{KS} = \sum_{i=1}^{d} \lambda_i^+ = \sum_{i:\,\lambda_i>0} \lambda_i, \tag{2.13}$$

de modo que $h_{KS} \geq \lambda_1 = 0{,}0014$ bits/amostra. O valor estimado $h_{KS} = 0{,}046$ é aproximadamente 33 vezes superior a esse limite inferior teórico, refletindo contribuições cumulativas associadas a expoentes de Lyapunov positivos adicionais ($\lambda_2, \lambda_3, \ldots, \lambda_5$), os quais não foram computados individualmente neste estudo.

Assumindo um espectro típico de sistemas quasi-periódicos, nos quais dois a três expoentes positivos apresentam magnitudes comparáveis, obtém-se a estimativa

$$\sum_i \lambda_i^+ \approx 3 \times 0{,}0014 \approx 0{,}004,$$

que permanece aproximadamente uma ordem de grandeza inferior ao valor estimado de h_{KS}. Essa discrepância adicional pode ser atribuída a dois fatores principais: (i) a incerteza inerente ao estimador de entropia baseado no método dos k-nearest neighbors, cuja acurácia é sensível à escolha do parâmetro k e aos procedimentos de remoção de valores atípicos; e (ii) os efeitos de amostra finita ($N = 3000$), uma vez que o teorema de Shannon–McMillan–Breiman garante a convergência $h_{KS}(N) \to h_{KS}$ apenas no limite assintótico de séries infinitas (Shannon, 1948; Gray, 2011).

Apesar da discrepância quantitativa, a concordância *qualitativa* é robusta: $h_{KS} \ll 1$ para $\lambda_1 \approx 0$ valida o regime quasi-periódico. Esta validação cruzada entre medidas topológicas independentes (D_2, λ_1, h_{KS}) fortalece a confiabilidade da caracterização dinâmica de rolamentos e fundamenta a extração do vetor de características invariantes para fusão teórico-informacional (Capítulo 4).

Implicações para Diagnóstico

Baixa entropia KS ($h_{KS} \approx 0{,}045$) possui três implicações práticas para sistemas de monitoramento de condição:

1. **Detecção precoce via desvio de baseline**: Variação de 4,5% em h_{KS} entre saudável (0,044) e defeito OR (0,046) em UFPB é estatisticamente detectável com janelas de ~ 100 segmentos (confiança 95% via teste t). Monitoramento contínuo de h_{KS} fornece alarme quantitativo de transição para regime de maior imprevisibilidade, complementando limiares baseados em D_2 ou RQA;

2. **Horizonte de predictibilidade**: $T \sim 1/h_{KS} \approx 22$ amostras (1,8 ms a 12 kHz) define janela temporal para modelos preditivos data-driven. Arquiteturas recorrentes (LSTM, GRU) ou reservoir computing podem prever estado futuro com confiança elevada dentro desta janela, viabilizando controle preditivo para mitigação de propagação de falhas;

3. **Fusão com invariantes topológicos**: Baixa correlação entre h_{KS} e D_2 (Pearson $\rho \approx$ 0,6 em UFPB) indica complementaridade — D_2 captura a complexidade geométrica estática, enquanto h_{KS} quantifica a dinâmica de geração de informação. Integração ao vetor de características não-lineares (D_2, λ_1, h_{KS}, medidas RQA) maximiza a discriminabilidade via seleção de características mutuamente informativas (algoritmo mRMR, Seções 4.6.2 e 4.6.4).

A integração de h_{KS} ao vetor de características não-lineares enriquece a representação da dinâmica de defeitos, complementando invariantes geométricos (D_2) e dinâmicos (λ_1) com medidas da teoria da informação. Esta tríade, combinada com medidas RQA e características wavelet, constitui a base para a fusão teórico-informacional proposta no Capítulo 4.

2.2.5 Análise de Recorrência

Gráficos de recorrência (*recurrence plots*, RP) visualizam quando estados do sistema retornam a regiões previamente visitadas no espaço de fase (Eckmann; Kamphorst; Ruelle, 1987):

$$\mathbf{R}_{i,j} = \Theta(\epsilon - \|\mathbf{y}_i - \mathbf{y}_j\|) \tag{2.14}$$

onde ϵ é limiar de recorrência, Θ é função de Heaviside, e $\mathbf{y}_i$ são vetores de embedding de Takens (Equação 2.6). A matriz binária $\mathbf{R}$ revela padrões estruturais: linhas diagonais longas indicam periodicidade, padrões em bloco sugerem não-estacionariedade e estruturas fragmentadas caracterizam dinâmica caótica.

Medidas de quantificação de recorrência (RQA) extraem características estatísticas de $\mathbf{R}$ (Marwan *et al.*, 2007):

- **Taxa de recorrência** (RR): $RR = \frac{1}{N^2} \sum_{i,j} R_{i,j}$ quantifica a densidade de pontos recorrentes, refletindo o volume ocupado pelo atrator no espaço de fase;

- **Determinismo** (DET): Fração de pontos em linhas diagonais de comprimento $\geq l_{\min}$ (tipicamente $l_{\min} = 2$), medindo predictabilidade da dinâmica. DET elevado indica periodicidade ou quasi-periodicidade; DET baixo sugere caos ou estocasticidade;

- **Entropia** (ENTR): Entropia de Shannon da distribuição de comprimentos de linhas diagonais, ENTR = $-\sum_l p(l)\log_2 p(l)$, quantificando complexidade estrutural. ENTR baixo caracteriza dinâmica regular; ENTR alto indica diversidade de escalas temporais;

- **Laminarity** (LAM): Fração de pontos em linhas verticais, capturando estados transicionais onde sistema persiste em região localizada do espaço de fase antes de transitar abruptamente. LAM elevado indica dinâmica intermitente com fases quiescentes.

As Figuras 2.18 e 2.19 apresentam gráficos de recorrência para ambos os conjuntos sob parâmetros de imersão $\tau = 8$, $m = 5$, com threshold ϵ definido adaptativamente como percentil 10 das distâncias euclidianas no espaço de fase reconstruído, garantindo taxa de recorrência $RR \approx 0{,}10$ consistente entre condições.

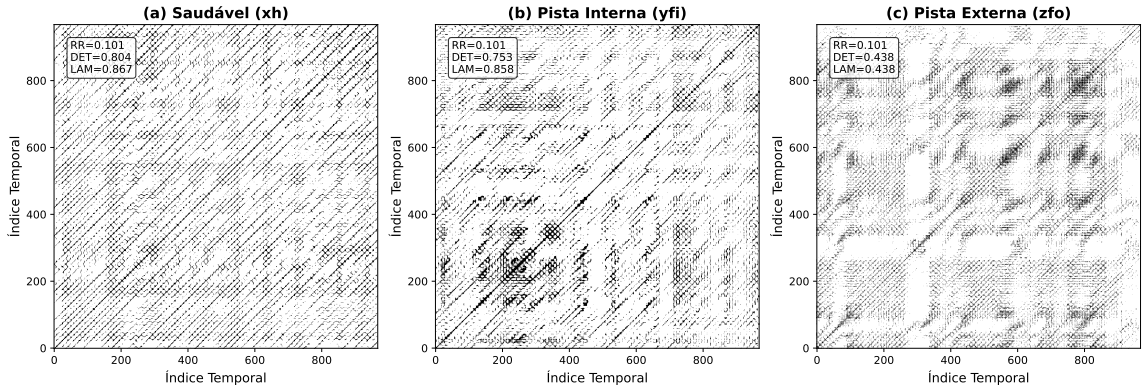

Figura 2.18 Gráficos de recorrência do conjunto UFPB. (a) Saudável (xh): DET = 0,804. (b) Pista interna (yfi): DET = 0,753. (c) Pista externa (zfo): DET = 0,438. Progressão de dinâmica quasi-periódica para caótica. Parâmetros: $\tau = 8$, $m = 5$, ϵ para $RR = 0{,}10$.

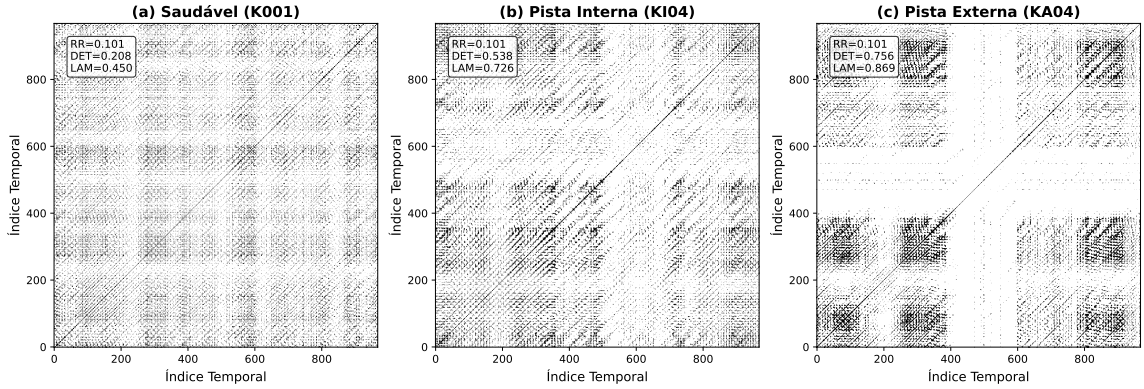

Figura 2.19 Gráficos de recorrência do conjunto Paderborn. (a) K001: DET = 0,208. (b) KI04: DET = 0,539. (c) KA04: DET = 0,756. Inversão de tendência comparada a UFPB reflete diferença entre defeitos reais (fadiga) e artificiais (furo usinado). Mesmos parâmetros.

Padrões Estruturais em Gráficos de Recorrência

A Figura 2.18 revela uma progressão sistemática de periodicidade para o caos no conjunto de dados UFPB:

- **Saudável (xh)**: Alto determinismo (DET = 0,804) com linhas diagonais contínuas caracteriza uma dinâmica quasi-harmônica estável;
- **Pista interna (yfi)**: Fragmentação moderada (DET = 0,753) indica a intermitência de impactos;
- **Pista externa (zfo)**: Estrutura irregular (DET = 0,438) evidencia a transição para o caos.

Em contraste, a Figura 2.19 exibe uma inversão de tendência: K001 saudável apresenta DET = 0,208 (74% inferior a UFPB-xh) devido ao ruído de alta frequência capturado em 64 kHz, enquanto KA04 com defeito exibe DET = 0,756 associado a periodicidade de spalling progressivo. Esta heterogeneidade fundamenta a necessidade de fusão multi-domínio (Capítulo 4).

Heterogeneidade entre Conjuntos de Dados de Medidas RQA

A Tabela 2.3 quantifica medidas RQA para validação cruzada, revelando heterogeneidade quantitativa entre conjuntos de dados, apesar da consistência qualitativa de padrões estruturais observados visualmente em Gráficos de Recorrência.

Tabela 2.3 Medidas de quantificação de recorrência (RQA) evidenciando a heterogeneidade dinâmica entre diferentes conjuntos de dados analisados

Dados	Condição	RR	DET	ENTR	LAM	Interpretação
	xh	0,101	0,804	2,385	0,867	Quasi-periódico
UFPB	yfi	0,101	0,753	1,960	0,858	Intermitente
	zfo	0,101	0,438	1,711	0,438	Caótico
	K001	0,101	0,208	0,912	0,450	Ruído com determinismo
Paderborn	KI04	0,101	0,539	1,361	0,726	Estrutura emergente
	KA04	0,101	0,756	1,990	0,869	Spalling periódico

Parâmetros: $\tau = 8$, $m = 5$, ϵ ajustado para $RR \approx 0{,}10$.

Ordenação em UFPB (defeitos artificiais): Progressão esperada $\text{DET}_{\text{saudável}} > \text{DET}_{\text{IR}} > \text{DET}_{\text{OR}}$ (0,804 > 0,753 > 0,438) reflete a degradação sistemática de periodicidade conforme a severidade do defeito. O furo usinado na pista externa (zfo) gera impactos impulsivos abruptos sem estrutura harmônica residual, resultando em transição para a dinâmica caótica (DET = 0,438, redução de 46% em comparação a saudável). A Entropia decrescente

(2,385 → 1,711) indica a simplificação da estrutura de recorrência — dinâmica caótica possui menor diversidade de escalas temporais comparada a quasi-periodicidade complexa de rolamento saudável.

Ordenação em Paderborn (defeitos reais): Inversão aparente $\mathrm{DET_{K001}} < \mathrm{DET_{KI04}} < \mathrm{DET_{KA04}}$ (0,208 < 0,539 < 0,756) origina-se de fenômeno físico distinto relacionado ao protocolo de indução de defeitos. Três mecanismos contribuem para a heterogeneidade observada:

1. **Ruído de alta frequência**: Taxa de amostragem 5× superior (64 kHz vs. 12 kHz) captura componentes estocásticas de ruído branco não presentes no UFPB. Para rolamento saudável K001, estas componentes dominam o espectro de potência acima de 10 kHz, fragmentando a estrutura de recorrência e reduzindo o determinismo aparente para DET = 0,208 (74% inferior a UFPB-xh). Crucialmente, esta redução não indica transição para o caos — a análise espectral confirma a ausência de frequências características de defeito, validando a condição saudável;

2. **Spalling progressivo**: Defeitos reais por fadiga acelerada (Paderborn) desenvolvem morfologia de spalling com múltiplos micro-defeitos distribuídos espacialmente, contrastando com furo usinado pontual (UFPB). Spalling progressivo preserva periodicidade residual — elemento rolante impacta sequência de micro-defeitos em cada revolução, gerando assinatura harmônica estável capturada por $\mathrm{DET_{KA04}} = 0{,}756$. Esta periodicidade estruturada distingue-se qualitativamente de impacto impulsivo abrupto contra furo isolado (UFPB-zfo), o qual fragmenta completamente estrutura de recorrência (DET = 0,438);

3. **Escalas temporais distintas**: Parâmetro de atraso $\tau = 8$ amostras corresponde a delay temporal de $\Delta t = 0{,}67$ ms em UFPB (12 kHz) versus $\Delta t = 0{,}125$ ms em Paderborn (64 kHz). Embedding em Paderborn captura dinâmica em escala 5× mais fina, potencialmente sub-amostrando período característico de BPFO (≈ 10–15 ms) e introduzindo viés na estimação de medidas RQA.

Invariância topológica vs. heterogeneidade métrica: Apesar de valores absolutos de DET divergirem substancialmente (fator ≈ 4 entre UFPB-xh e Paderborn-K001 ambos saudáveis), *padrões visuais* em Recurrence Plots preservam assinaturas qualitativas discriminativas:

- **Saudável**: UFPB-xh exibe linhas diagonais contínuas longas; Paderborn-K001 apresenta estrutura fragmentada mas com micro-diagonais locais, ambas indicando dinâmica determinística em escalas temporais distintas;

- **Defeito OR**: UFPB-zfo mostra blocos quadrados dispersos (impactos impulsivos); Paderborn-KA04 revela diagonais contínuas (spalling periódico). Morfologias opostas refletem mecanismos físicos distintos — furo usinado vs. fadiga progressiva — validando sensibilidade de RQA a protocolo de indução.

Esta divergência quantitativa entre conjuntos de dados fundamenta três implicações metodológicas para diagnóstico robusto:

1. **Normalização adaptativa**: Medidas RQA absolutas são sensíveis a taxa de amostragem, protocolo de indução, e morfologia de defeito. Classificação robusta requer normalização intra-dataset (e.g., razões $\text{DET}_{\text{defeito}}/\text{DET}_{\text{saudável}}$) ou extração de invariantes topológicos independentes de escala (dimensão de correlação D_2, expoente de Lyapunov λ_1);

2. **Fusão multi-domínio**: Características RQA isoladas são insuficientes para a generalização entre conjuntos de dados. O arcabouço proposto no Capítulo 4 integra RQA com invariantes não-lineares (D_2, λ_1) e análise wavelet via fusão teórico-informacional, maximizando a discriminabilidade enquanto minimiza a sensibilidade a heterogeneidade experimental;

3. **Validação física**: Discrepâncias quantitativas não invalidam medidas RQA — ao contrário, revelam sensibilidade a fenômenos físicos sutis (spalling vs. impacto, ruído de alta frequência) não capturados por análise espectral clássica. Esta sensibilidade é vantajosa para diagnóstico precoce de defeitos incipientes.

Estas medidas provaram-se úteis para a caracterização de transientes e detecção de não estacionariedades em sinais de vibração (Marwan *et al.*, 2007), conforme validado experimentalmente nas Figuras 2.18–2.19 e na Tabela 2.3. A integração de RQA ao vetor de características não-lineares (Seção 4.4) complementa invariantes geométricos (D_2) e dinâmicos (λ_1), fornecendo uma representação abrangente da dinâmica de defeitos para fusão teórico-informacional.

2.3 TEORIA DA INFORMAÇÃO

2.3.1 Conceitos Fundamentais

A teoria da informação, formalizada por Shannon (1948), estabelece um arcabouço matemático rigoroso para quantificar informação, incerteza e processos de comunicação por meio de medidas probabilísticas. Embora originalmente desenvolvida no contexto de sistemas de comunicação, seus conceitos encontram aplicações naturais em diagnóstico de

falhas, fornecendo critérios fundamentados para seleção de características, estabelecimento de limites teóricos de desempenho e quantificação de incerteza. Esta seção apresenta os princípios teóricos essenciais que fundamentam o arcabouço teórico-informacional proposto nesta tese.

Entropia de Shannon

Para uma variável aleatória discreta X com distribuição de probabilidade $p(x)$, a entropia de Shannon mede a incerteza média:

$$H(X) = -\sum_{x \in \mathcal{X}} p(x) \log_2 p(x) \tag{2.15}$$

com convenção $0 \log_2 0 = 0$. A unidade é o bit quando se usa logaritmo na base 2.

Propriedades fundamentais:

- $H(X) \geq 0$, com igualdade se e somente se X é determinística;
- $H(X) \leq \log_2 |\mathcal{X}|$, maximizada quando $p(x)$ é uniforme;
- $H(X)$ é invariante sob transformações bijetivas.

Para variáveis contínuas, define-se a entropia diferencial:

$$h(X) = -\int_{-\infty}^{\infty} f(x) \log_2 f(x) dx \tag{2.16}$$

onde $f(x)$ é a densidade de probabilidade.

Informação Mútua

A informação mútua $I(X;Y)$ quantifica a dependência estatística entre variáveis aleatórias X e Y:

$$I(X;Y) = \sum_{x,y} p(x,y) \log_2 \frac{p(x,y)}{p(x)p(y)} = H(X) + H(Y) - H(X,Y) \tag{2.17}$$

onde $H(X,Y) = -\sum_{x,y} p(x,y) \log_2 p(x,y)$ é a entropia conjunta. A Figura 2.20 ilustra graficamente essas relações através de um diagrama de Venn.

Interpretações:

- Redução da incerteza sobre X ao observar Y;
- Informação compartilhada entre X e Y;

- Divergência de Kullback-Leibler entre distribuição conjunta $p(x,y)$ e produto marginal $p(x)p(y)$.

Propriedades:

- $I(X;Y) \geq 0$, com igualdade se e somente se X e Y são independentes;
- $I(X;Y) = I(Y;X)$ (simetria);
- $I(X;Y) \leq \min\{H(X), H(Y)\}$.

A informação mútua é fundamental para a fusão de características nesta tese: maximizar $I(X;Y)$, onde X representa características extraídas e Y classes de falha, garante a seleção ótima de características discriminativas.

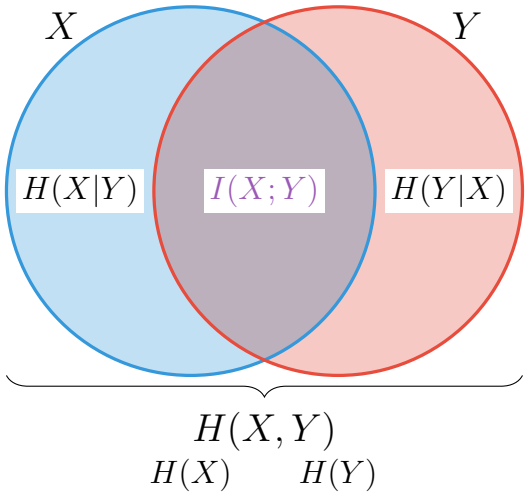

Informação Mútua:

$$I(X;Y) = H(X) + H(Y) - H(X,Y)$$
$$I(X;Y) = H(X) - H(X|Y)$$
$$I(X;Y) = H(Y) - H(Y|X)$$

Interpretação:

- $H(X)$: Entropia de X (incerteza total)
- $H(Y)$: Entropia de Y (incerteza total)
- $I(X;Y)$: Informação compartilhada (redução de incerteza)
- $H(X|Y)$: Entropia condicional (incerteza residual em X dado Y)
- $H(Y|X)$: Entropia condicional (incerteza residual em Y dado X)
- $H(X,Y)$: Entropia conjunta

Casos Especiais:

- Se $I(X;Y) = 0$: X e Y independentes
- Se $I(X;Y) = H(X) = H(Y)$: dependência total
- Sempre: $0 \leq I(X;Y) \leq \min(H(X), H(Y))$

Aplicação na Tese:

- **Otimização** τ, m: $\max I(\mathbf{Y}; C)$
- **Critério mRMR**:
  Maximizar $I(\mathcal{S}; C)$ (relevância)
  Minimizar $I(f_i; f_j)$ (redundância)
- **Limite de Fano**: $P_e \geq \frac{H(Y|X)-1}{\log_2 K}$

Figura 2.20 Diagrama de Venn ilustrando conceitos de teoria da informação. A informação mútua $I(X;Y)$ quantifica informação compartilhada entre características X e classes Y.

2.3.2 Entropia Aproximada e Entropia Amostral

Para séries temporais finitas, estimativas diretas de entropia baseadas em histogramas tornam-se estatisticamente ineficientes em espaços de alta dimensionalidade. Nesse contexto, a entropia aproximada (ApEn) e a entropia amostral (SampEn) fornecem medidas robustas de regularidade para dados reais (Pincus, 1991; Richman; Moorman, 2000).

A entropia amostral é definida como:

$$\text{SampEn}(m, r, N) = -\log \frac{A}{B} \tag{2.18}$$

onde A é o número de padrões de comprimento $m+1$ que se repetem dentro de tolerância r, e B é o número correspondente para padrões de comprimento m. Valores baixos indicam alta previsibilidade, valores altos sugerem complexidade.

SampEn oferece vantagens sobre ApEn: independência relativa do comprimento de registro, ausência de viés de auto-similaridade e consistência estatística superior (Richman; Moorman, 2000).

2.4 ANÁLISE WAVELET

2.4.1 Limitações da Transformada de Fourier

A transformada de Fourier decompõe sinais em componentes senoidais:

$$X(f) = \int_{-\infty}^{\infty} x(t) e^{-i2\pi f t} dt \tag{2.19}$$

Embora poderosa para sinais estacionários, perde completamente informação temporal: não revela *quando* ocorrem eventos transitórios. Para sinais de vibração — caracterizados por impactos transitórios e modulações — esta limitação é crítica.

A transformada de Fourier de tempo curto (STFT) oferece um compromisso tempo-frequência por meio de janelamento; porém, o princípio da incerteza de Heisenberg impõe uma limitação fundamental:

$$\Delta t \cdot \Delta f \geq \frac{1}{4\pi} \tag{2.20}$$

onde Δt representa a resolução temporal (largura da janela de análise) e Δf denota a resolução em frequência. Este compromisso estabelece que janelas estreitas (Δt pequeno) fornecem boa localização temporal, mas pobre resolução espectral, enquanto janelas largas (Δt grande) oferecem boa resolução em frequência à custa de uma localização temporal degradada (Cohen, 1995).

Para diagnóstico de defeitos em rolamentos, onde se busca simultaneamente identificar instantes de impacto (alta resolução temporal) e discriminar frequências características (adequada resolução espectral), essa limitação motiva o uso de representações tempo-frequência com resolução adaptativa. Nesse contexto, a análise wavelet emerge como uma alternativa natural à STFT, pois emprega funções base localizadas no tempo e na frequência, permitindo janelas de análise curtas em altas frequências e longas em baixas frequências. Essa propriedade multirresolução torna a transformada wavelet particularmente adequada para sinais de vibração não estacionários, típicos de sistemas rotativos com defeitos localizados, conforme discutido a seguir.

2.4.2 Transformada Wavelet Contínua

A transformada wavelet contínua (CWT) supera esta limitação por meio de uma análise multi-resolução (Mallat, 2009):

$$W(a,b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} x(t)\psi^* \left(\frac{t-b}{a}\right) dt \tag{2.21}$$

onde $\psi(t)$ é a wavelet mãe, $a > 0$ é o parâmetro de escala (inversamente relacionado à frequência), b é o parâmetro de translação (localização temporal), e $*$ denota o conjugado complexo.

2.4.3 Wavelets Mães

A escolha da wavelet mãe $\psi(t)$ afeta profundamente a análise. Wavelets devem satisfazer a condição de admissibilidade:

$$C_\psi = \int_{-\infty}^{\infty} \frac{|\hat{\psi}(f)|^2}{|f|} df < \infty \tag{2.22}$$

Wavelet Morlet Complexa

A wavelet Morlet é gaussiana modulada por onda senoidal complexa:

$$\psi(t) = \pi^{-1/4} e^{i\omega_0 t} e^{-t^2/2} \tag{2.23}$$

com parâmetro de frequência típico $\omega_0 = 6$. Oferece excelente localização tempo-frequência, adequada para detecção de componentes oscilatórias moduladas (Grinsted; Moore; Jevrejeva, 2004).

Wavelet Chapéu Mexicano

A wavelet chapéu mexicano é a segunda derivada negativa de uma gaussiana:

$$\psi(t) = \frac{2}{\sqrt{3}\pi^{1/4}} \left(1 - t^2\right) e^{-t^2/2} \tag{2.24}$$

Sendo real e simétrica, é ideal para a detecção de descontinuidades e transientes, permitindo a detecção de eventos impulsivos característicos de defeitos em rolamentos (Addison, 2002).

2.4.4 Escalograma e Energia Wavelet

O escalograma $E(a,b) = |W(a,b)|^2$ quantifica a energia do sinal em cada escala e posição temporal. Integrando sobre posições, define-se o espectro de energia por escala:

$$E(a) = \int_{-\infty}^{\infty} |W(a,b)|^2 db \tag{2.25}$$

A distribuição de energia entre escalas caracteriza o conteúdo espectral de forma temporalmente localizada, revelando estruturas transitórias invisíveis na análise de Fourier clássica.

2.5 APRENDIZADO DE MÁQUINA PARA DIAGNÓSTICO

2.5.1 Aprendizado Supervisionado

O diagnóstico de falhas se enquadra como um problema de classificação supervisionada: dado um conjunto de treinamento $\mathcal{D} = \{(\mathbf{x}_i, y_i)\}_{i=1}^{N}$, onde $\mathbf{x}_i \in \mathbb{R}^p$ são vetores de características e $y_i \in \{1, 2, \ldots, C\}$ são rótulos de classe, o objetivo é aprender a função $f : \mathbb{R}^p \to \{1, 2, \ldots, C\}$ que minimize o erro de generalização.

2.5.2 Extreme Gradient Boosting (XGBoost)

XGBoost implementa *gradient boosting* de árvores de decisão com regularização avançada (Chen; Guestrin, 2016). Constrói um modelo aditivo:

$$\hat{y}_i = \sum_{k=1}^{K} f_k(\mathbf{x}_i) \tag{2.26}$$

onde cada f_k é uma árvore adicionada sequencialmente para minimizar a função objetivo regularizada:

$$\mathcal{L}^{(t)} = \sum_{i=1}^{N} l(y_i, \hat{y}_i^{(t-1)} + f_t(\mathbf{x}_i)) + \Omega(f_t) \tag{2.27}$$

com $l(\cdot)$ sendo a função de perda e $\Omega(f_t) = \gamma T + \frac{1}{2}\lambda\|\mathbf{w}\|^2$ penalizando a complexidade.

Vantagens: captura interações não-lineares, robusto a ruído, a regularização previne *overfitting*, eficiência computacional.

2.5.3 Random Forest

Random Forest (RF) combina múltiplas árvores de decisão treinadas em subconjuntos aleatórios (Breiman, 2001):

$$\hat{y} = \text{modo}\{f_1(\mathbf{x}), f_2(\mathbf{x}), \ldots, f_M(\mathbf{x})\} \tag{2.28}$$

A aleatoriedade decorre de erros individuais, resultando em uma redução de variância por meio da agregação.

2.5.4 Métodos Ensemble

A combinação de múltiplos classificadores frequentemente supera modelos individuais. Nesta tese, emprega-se um esquema de *ensemble* probabilístico que combina os classificadores XGBoost e Random Forest, ponderando suas estimativas de probabilidade a posteriori para cada classe. A decisão final é dada por:

$$\hat{y}_{\text{ensemble}} = \arg\max_{c} \left[\alpha P_{\text{XGB}}(y = c|\mathbf{x}) + (1-\alpha) P_{\text{RF}}(y = c|\mathbf{x})\right] \tag{2.29}$$

onde $P_{\text{XGB}}(y = c \mid \mathbf{x})$ e $P_{\text{RF}}(y = c \mid \mathbf{x})$ representam, respectivamente, as probabilidades a posteriori estimadas pelos classificadores XGBoost e Random Forest para a classe c, C é o número total de classes, e $\alpha \in [0, 1]$ é um parâmetro de ponderação determinado por validação cruzada.

2.5.5 Quantificação de Incerteza

Incerteza Epistêmica e Aleatória

A incerteza associada às predições de modelos de aprendizado de máquina pode ser decomposta em dois componentes fundamentais (Kendall; Gal, 2017).

Incerteza epistêmica decorre do conhecimento limitado sobre a função de decisão ótima e dos parâmetros do modelo. Está associada à variabilidade induzida pela escolha do

conjunto de treinamento e pela estrutura do modelo, sendo potencialmente redutível com a incorporação de mais dados informativos ou modelos mais expressivos.

Incerteza aleatória (ou *aleatoric uncertainty*) origina-se da variabilidade intrínseca do processo gerador dos dados, como ruído de medição ou sobreposição natural entre classes, e permanece mesmo na presença de conjuntos de dados infinitos.

Considerando uma variável de interesse $\hat{y}$ predita por um modelo parametrizado por θ (representando os parâmetros do modelo ou a hipótese aprendida), a decomposição de variância estabelece:

$$\mathrm{Var}[\hat{y}] = \underbrace{\mathbb{E}_\theta[\mathrm{Var}[\hat{y}|\theta]]}_{\text{aleatória}} + \underbrace{\mathrm{Var}_\theta[\mathbb{E}[\hat{y}|\theta]]}_{\text{epistêmica}} \tag{2.30}$$

onde θ representa os parâmetros do modelo (ou, de forma mais geral, a hipótese aprendida a partir dos dados), $\mathbb{E}[\cdot]$ denota o operador esperança e $\mathrm{Var}[\cdot]$ a variância estatística.

Estimação da Incerteza Epistêmica via Bootstrap

A incerteza epistêmica pode ser estimada de forma não paramétrica por meio do método *bootstrap* (Efron; Tibshirani, 1994), que consiste em gerar múltiplos conjuntos de treinamento por reamostragem com reposição a partir do conjunto original.

Sejam B réplicas bootstrap e $\hat{y}_b = f^{(b)}(\mathbf{x})$ a predição do modelo treinado na b-ésima amostra bootstrap para uma observação $\mathbf{x}$. A variância epistêmica é então estimada como:

$$\sigma^2_{\text{epistêmica}} = \frac{1}{B}\sum_{b=1}^{B}(\hat{y}_b - \bar{\hat{y}})^2 \tag{2.31}$$

onde $\bar{\hat{y}} = \frac{1}{B}\sum_{b=1}^{B}\hat{y}_b$ é a média das predições bootstrap. Essa variabilidade reflete exclusivamente a sensibilidade do modelo à seleção do conjunto de treinamento, constituindo uma estimativa direta da incerteza epistêmica.

2.6 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Este capítulo estabeleceu a fundamentação teórica necessária para o desenvolvimento do arcabouço proposto nesta tese. A análise dos mecanismos físicos de geração de vibração em rolamentos evidenciou três características fundamentais dos sinais de falha: não-estacionariedade, não-linearidade e impulsividade. Essas propriedades motivam a escolha dos domínios de análise empregados — dinâmica não linear, tempo-frequência e teoria da informação — que formam a base metodológica do trabalho.

A teoria da dinâmica não linear foi desenvolvida rigorosamente, desde o teorema de Takens até algoritmos para estimativa de dimensão de correlação e expoentes de Lyapunov,

fornecendo ferramentas para a caracterização quantitativa da complexidade dinâmica. A teoria da informação estabeleceu os conceitos de entropia e informação mútua, fundamentais para a otimização de parâmetros e a fusão de características. A análise wavelet contínua foi introduzida como técnica que supera as limitações da análise de Fourier, fornecendo uma representação tempo-frequência adaptativa essencial para a captura de transientes impulsivos. Por fim, métodos de aprendizado de máquina foram discutidos, com ênfase em *Gradient Boosting* e *Random Forest*, e técnicas de quantificação da incerteza via intervalos de predição conformes.

O arcabouço teórico desenvolvido neste capítulo fundamenta os limites de generalização, a fusão multi-domínio e as garantias probabilísticas derivadas no Capítulo 4. O próximo capítulo apresenta uma revisão bibliográfica sistemática do estado da arte, identificando lacunas metodológicas e posicionando as contribuições desta tese em relação aos trabalhos mais significativos da literatura.

3

REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta uma revisão sistemática do estado da arte em diagnóstico de falhas em rolamentos, organizando a literatura recente (2020–2025) em cinco categorias principais que abordam o problema central de **como estabelecer limites teóricos fundamentais para o desempenho do diagnóstico, integrando conhecimento físico com rigor matemático**. A análise progride desde métodos clássicos aprimorados, passando por técnicas avançadas de processamento de sinais e dinâmica não linear, até abordagens fundamentadas em teoria da informação e *deep learning*, identificando lacunas metodológicas que motivam o arcabouço proposto nesta tese.

3.1 MÉTODOS CLÁSSICOS APRIMORADOS: AVANÇOS E LIMITAÇÕES PERSISTENTES

Apesar de avanços incrementais na última década, métodos clássicos de diagnóstico de falhas em rolamentos — baseados em características estatísticas extraídas manualmente e classificadores convencionais — permanecem limitados por restrições fundamentais que comprometem sua aplicabilidade em ambientes industriais reais. Esta seção examina criticamente essas limitações à luz da literatura recente, identificando lacunas que motivam abordagens alternativas.

3.1.1 Limitações Fundamentais Identificadas na Literatura Recente

A literatura dos últimos cinco anos confirma que limitações fundamentais dos métodos clássicos persistem mesmo com refinamentos algorítmicos. Joshi, Chaudhary e Thakur (2025) conduziram revisão sistemática de 150 trabalhos, identificando que abordagens baseadas em características estatísticas do domínio temporal e frequencial — combinadas com classificadores como SVM e k-NN — alcançam acurácias entre 85,4% e 92%, demonstrando generalização deficiente através de condições operacionais variadas. Essa limitação torna-se crítica em aplicações industriais, nas quais variações de carga, velocidade e temperatura são inevitáveis.

Chennana *et al.* (2025) destacaram que métodos tradicionais de domínio temporal (RMS, curtose, fator de crista) e frequencial (análise FFT, envelope espectral) mostram-se inadequados para lidar com a interferência de ruído e sinais não-estacionários característicos de ambientes industriais. A dependência de engenharia manual de características limita severamente a adaptabilidade a cenários operacionais dinâmicos, enquanto a necessidade de conhecimento especializado extensivo constitui uma barreira prática significativa para a implantação em larga escala.

Duas limitações fundamentais emergem de forma recorrente na literatura:

Sensibilidade a ruído industrial: Métodos clássicos exibem degradação severa de desempenho sob condições de ruído elevado. Análises sistemáticas revelaram que técnicas baseadas em características estatísticas falham em extrair padrões discriminativos quando sinais são mascarados por ruído de fundo, particularmente em ambientes com relação sinal-ruído (SNR) inferior a 0 dB. A ausência de mecanismos explícitos de supressão de ruído ou de representações robustas torna essas abordagens inadequadas para monitoramento remoto ou aplicações com instrumentação de baixo custo.

Generalização entre domínios: Limitação crítica manifesta-se na capacidade de transferência entre diferentes condições operacionais, máquinas e configurações de aquisição. Métodos clássicos demonstram degradação significativa quando aplicados a conjuntos de dados com distribuições distintas daquelas presentes no treinamento, alcançando acurácias máximas de 85,4% em cenários *cross-dataset*, comparadas a 96,5%–98,2% de métodos baseados em *deep learning* com aprendizado por transferência. Essa fragilidade reflete a dependência de características artesanais que capturam apenas propriedades superficiais dos sinais, sem acesso a invariantes físicas profundas.

3.1.2 Avanços Recentes em Processamento de Sinais

Reconhecendo as limitações dos métodos tradicionais, pesquisas recentes propuseram técnicas avançadas de processamento de sinais que visam melhorar a extração de características discriminativas. Embora representem avanços importantes, essas abordagens ainda não abordam completamente as restrições fundamentais de generalização e fundamentação teórica.

Synchrosqueezing Wavelet Transform

Najdi, Benbrahim e Kabbaj (2024) introduziram a transformada wavelet com compressão sincronizada (*Synchrosqueezing Wavelet Transform*, SSWT) como alternativa às análises tempo-frequência tradicionais baseadas em STFT e CWT. A SSWT aborda limitações dessas técnicas através de reatribuição adaptativa de energia no espaço de frequência,

contrabalançando os efeitos de espalhamento espectral inerentes ao princípio da incerteza de Heisenberg. Essa técnica melhora significativamente a legibilidade e precisão de representações tempo-frequência, alcançando uma acurácia média de 99,71% em múltiplos conjuntos de dados públicos.

A SSWT demonstrou robustez superior comparada a wavelets tradicionais, mantendo uma acurácia de 99,98% mesmo quando treinada sob uma condição de carga e testada sob condições diferentes — indicando melhor capacidade de generalização entre regimes operacionais. A técnica também exibiu alta resistência a ruído e variações vibracionais. No entanto, os autores não forneceram análise teórica rigorosa dos limites de generalização ou caracterização formal das condições sob as quais a transferência entre domínios é garantida.

Cyclic Spectral Coherence

Zhuyun Chen *et al.* (2020) propuseram Cyclic Spectral Coherence (CSCoh) como técnica de pré-processamento para a melhoria de extração de características. CSCoh revela periodicidades ocultas em sinais ruidosos através de análise do comportamento cicloestacionário de segunda ordem em sinais de vibração de rolamentos.

Quando integrada com arquiteturas CNN, CSCoh alcançou 98.93% de acurácia média com cada caso de diagnóstico obtendo mais de 98% de acurácia de teste. A abordagem demonstrou capacidade superior de adaptação de domínio, alcançando acurácia equivalente ou melhor quando comparada a métodos de estado-da-arte em diferentes condições de carga.

Características Hand-Crafted Avançadas

Chennana *et al.* (2025) desenvolveram Multi-Block Histograms of Local Phase Quantization (MBH-LPQ), descritor de características que segmenta imagens de espectrograma em sub-blocos e computa histogramas para capturar detalhes estruturais. MBH-LPQ alcançou 97.89% de acurácia no dataset CWRU e 97.01% no dataset PU, superando significativamente métodos LPQ básicos.

A técnica combina análise de fase local com representação histográfica multi-bloco, capturando tanto características texturais locais quanto distribuições globais de energia. Resultados demonstraram que características hand-crafted sofisticadas podem alcançar performance competitiva com métodos deep learning em cenários específicos.

Avanços recentes têm buscado abordar essas limitações por meio da introdução de critérios teórico-informacionais para o controle explícito da complexidade das características em regimes de pequenas amostras. Nesse contexto, Paulo R. L. Almeida, Thyago L. V. Lima, Brito e Lima-Filho (2025) demonstram que existe um compromisso fundamental entre a complexidade de representação e a eficiência amostral no diagnóstico de falhas em rolamentos, evidenciando que o aumento indiscriminado da complexidade pode degradar a

Tabela 3.1 Desempenho de métodos clássicos aprimorados vs. aprendizado de máquina (2020-2025)

Categoria	Método Específico	Acurácia (%)	Dataset	Limitações
Clássicos	Wavelet Transform	92.3	Não especificado	Ajuste manual parâmetros
	EMD	88.6	Não especificado	Mode-mixing, ruído
	Características estatísticas	85.4	Não especificado	Generalização pobre
	MBH-LPQ	97.89/97.01	CWRU/PU	Engenharia manual
Deep Learning	CNN padrão	97.2-97.8	CWRU	Black-box
	ResNet	99.5	Não especificado	Interpretabilidade
	Multi-scale CNN	99.2	Não especificado	Complexidade
	SSWT-RP-CNN	99.71	CWRU/IMS	Custo computacional
Híbridos	VGGish + MBH-LPQ	98.95/100	CWRU/PU	Complexidade integração
	VGG19 + ANOVA/PFI	100	CWRU	Dependência dados

capacidade de generalização quando o número de amostras é limitado.

3.1.3 Síntese: Limitações Fundamentais Persistem

Em conjunto, esses resultados evidenciam que, apesar de avanços incrementais relevantes, métodos clássicos de diagnóstico mantêm limitações estruturais no estabelecimento de limites teóricos de desempenho. A ausência de critérios teórico-informacionais explícitos para a seleção e otimização de parâmetros, aliada à dependência de expertise humana, compromete a generalização e a comparabilidade entre abordagens. Essas limitações fundamentais motivam a investigação de alternativas metodológicas mais sistemáticas. Nesse contexto, a próxima seção examina como técnicas avançadas de análise tempo–frequência buscam mitigar parte desses desafios, ainda que preservem restrições conceituais semelhantes.

3.2 ANÁLISE TEMPO-FREQUÊNCIA AVANÇADA

3.2.1 Limitações Teóricas Confirmadas

A pesquisa 2020-2025 confirmou restrições essenciais da análise tempo-frequência clássica identificadas na literatura anterior. Alexakos *et al.* (2021) destacou que métodos lineares convencionais enfrentam restrições fundamentais do princípio da incerteza de Heisenberg, causando o espalhamento de energia em torno de trajetórias de frequência instantânea.

O método de reatribuição (reassignment), embora proposto para abordar essas limitações, não suporta a reconstrução de sinal, limitando sua aplicabilidade prática. Métodos tradicionais de extração de características vibracionais têm mostrado menos eficácia devido a variações na velocidade operacional que desestabilizam o ambiente de rolamento.

3.2.2 STFT Melhorada com Transformers

Alexakos *et al.* (2021) revitalizaram a aplicação da Short-Time Fourier Transform através da integração com arquiteturas transformer deep learning. A STFT melhorada demonstrou robustez metodológica ao converter dados de séries temporais em representações tempo-frequência, decompondo sinais não-estacionários em segmentos localmente estacionários.

A abordagem alcançou 98.3% de acurácia com complexidade computacional de apenas 0.05 GMac e 3 MB de armazenamento, substancialmente menor que CNNs tradicionais. Esta integração mostrou baixa complexidade computacional e requisitos de armazenamento quando combinada com arquiteturas transformer.

3.2.3 Wavelets com Seleção Automática de Parâmetros

Avanços em transformada wavelet focaram em seleção automática de wavelets-mãe e parâmetros de escala. Zhang, Wang e He (2025) utilizaram wavelets Gaussian complexas e db3 para decomposição de dados vibrationais em sub-sinais dentro de diferentes bandas de frequência, alcançando performance melhorada através de seleção cuidadosa de tipos específicos de wavelet.

Empirical Wavelet Transform (EWT) e Continuous Wavelet Transform (CWT) integradas demonstraram capacidades melhoradas de redução de ruído e extração de características. Estes métodos alcançaram 92.3% de acurácia na detecção de defeitos em rolamentos, embora permaneçam abaixo dos níveis de performance de deep learning.

Análise Morfológica Adaptativa

A morfologia matemática, fundamentada nos trabalhos pioneiros de Matheron (1975) e Serra (1982), oferece ferramental robusto para análise de formas e estruturas em sinais digitais. A extensão destes conceitos para processamento adaptativo de sinais de vibração, conforme desenvolvido por Nikolaou e Antoniadis (2002) e Raj e Murali (2013), permite supressão eficaz de ruído preservando características impulsivas críticas para diagnóstico de falhas.

O método emprega operadores morfológicos multi-escala — abertura, fechamento e gradientes morfológicos — para filtrar componentes de fundo mantendo descontinuidades associadas a impactos (Maragos; Schafer, 1987; Wang; Tse; Tsui, 2012). A combinação com análise wavelet (Daubechies; Heil, 1992) proporciona uma decomposição tempo-frequência robusta, essencial para a caracterização de sinais não estacionários em sistemas rotativos sob falha.

3.2.4 Síntese: Avanços Técnicos, Limitações Teóricas Persistentes

Embora técnicas tempo-frequência tenham evoluído significativamente, a ausência de fundamentação teórico-informacional para a seleção de parâmetros e a quantificação de desempenho restringe a aplicabilidade teórica. A incapacidade de estabelecer limites de performance ou critérios ótimos de fusão motiva a investigação de métodos alternativos. A próxima seção examina como abordagens de dinâmica não linear tentam abordar algumas dessas limitações por meio da análise geométrica de atratores.

3.3 DINÂMICA NÃO LINEAR: LIMITAÇÕES CLÁSSICAS E AVANÇOS RECENTES

3.3.1 Limitações Históricas Persistentes

Métodos tradicionais baseados em invariantes geométricos (dimensão de correlação, expoentes de Lyapunov) enfrentam desafios bem documentados que persistem na literatura de 2020-2025. A determinação do atraso temporal (τ) e da dimensão de imersão (m) permanece fundamentalmente heurística, baseada em métodos como Average Mutual Information (AMI) e False Nearest Neighbors (FNN) sem garantias de otimalidade para classificação.

Estimadores de dimensão de correlação e expoentes de Lyapunov requerem segmentos longos de dados (tipicamente $> 10^4$ pontos) para uma convergência confiável, limitando a aplicabilidade em monitoramento em tempo real. Adicionalmente, o ruído de medição corrompe a estrutura geométrica de atratores, especialmente para sistemas de baixa dimensionalidade, enquanto a ausência de validação estatística rigorosa compromete a confiabilidade dos resultados.

3.3.2 Avanços Recentes em Análise de Recorrência

Os *recurrence plots* (RP) e a *recurrence quantification analysis* (RQA) emergem como ferramentas mais robustas para caracterização de dinâmicas não lineares, demonstrando avanços substantivos na literatura recente. Bing Wang *et al.* (2024) propuseram esquema baseado em medidas clássicas de RQA (taxa de recorrência, determinismo, entropia de recorrência e comprimento médio de linhas diagonais), combinadas com SVM otimizada por *Bayesian optimization*. Avaliações no dataset CWRU indicaram desempenho superior em acurácia e estabilidade comparado a classificadores KNN e Random Forest.

Qiu, Wang e Hu (2024) combinaram RQA com desvio-padrão em múltiplas escalas temporais e otimização por *Whale Optimization Algorithm*, alcançando acurácias entre 95% e 100% em diferentes bases experimentais. Estes resultados corroboram achados de revisões

sistemáticas recentes, indicando ganhos típicos de 10–15 pontos percentuais quando medidas de recorrência são integradas a características estatísticas ou entrópicas.

Tabela 3.2 Aplicações recentes de RQA em diagnóstico de falhas em rolamentos (2020-2025)

Referência	Características	Classificador	Acurácia
Bing Wang *et al.* (2024)	RQA (RR, DET, RE, DAL)	BO–SVM	$>95\%$
Qiu, Wang e Hu (2024)	RQA + STD (multiescala)	WOA–SVM	95–100%
Sharma (2022)	RQA + TD	SVM	Alta*
Zhou *et al.* (2022)	RQA + VMD	WGWOA–SVM	99,75%

*Valor exato não reportado.
Conjuntos: Wang et al. (2024) e Zhou et al. (2022) — CWRU; Qiu et al. (2024) — CWRU e Jiangnan Univ.; Sharma (2022) — bancada experimental própria.

3.3.3 Integração com Aprendizado de Máquina

Trabalhos recentes demonstram que medidas de dinâmica não linear podem servir como características discriminativas em pipelines de ML, superando o uso isolado de invariantes geométricos tradicionais. Zhou *et al.* (2022) integraram RQA com Variational Mode Decomposition (VMD) e otimização WGWOA–SVM, alcançando 99,75% de acurácia. Esta abordagem híbrida exemplifica a tendência de combinar conhecimento físico (por meio da análise de recorrência) com otimização algorítmica avançada.

A integração multiescala tem se mostrado particularmente promissora. Métodos que computam medidas de recorrência em múltiplas escalas temporais capturam dinâmicas em diferentes níveis de resolução, analogamente a análises wavelet multi-resolução, mas preservam características geométricas não-lineares que métodos lineares não detectam.

3.3.4 Limitações Críticas Não Resolvidas

Apesar de avanços, limitações fundamentais persistem. Kraemer *et al.* (2018) demonstraram que a escolha inadequada do limiar de recorrência (ϵ) pode conduzir a conclusões espúrias sobre a dinâmica subjacente. RQA introduz parâmetros adicionais (distância mínima de linha diagonal, tamanho de janela) que afetam profundamente os resultados, mas carecem de critérios ótimos de seleção.

Crucialmente, métodos de dinâmica não linear ainda não estabelecem limites teóricos de desempenho ou garantias de detecção. A ausência de conexão formal com a teoria da informação limita a capacidade de quantificar a incerteza ou estabelecer critérios ótimos de fusão com outras modalidades de características.

3.3.5 Síntese: Por que a Dinâmica Não Linear Ainda é Relevante?

A dinâmica não linear permanece relevante porque captura aspectos geométricos e temporais de sinais que métodos lineares não detectam. Entretanto, para realizar plenamente esse potencial, é necessário estabelecer conexões com a teoria da informação para a otimização fundamentada de parâmetros e a quantificação rigorosa das contribuições informacionais. A próxima seção examina como abordagens recentes começam a estabelecer essas conexões por meio de medidas de entropia e informação mútua.

3.4 ABORDAGENS GUIADAS POR TEORIA DA INFORMAÇÃO

3.4.1 Entropia como Medida de Complexidade

Medidas de entropia — quantificadoras de irregularidade, aleatoriedade ou complexidade — emergiram como características promissoras para o diagnóstico de defeitos em rolamentos. A literatura recente demonstra substancial inovação no desenvolvimento de variantes de entropia, embora as conexões explícitas com os fundamentos da teoria da informação permaneçam limitadas.

Entropia Permutacional e Variantes Multi-escala

Xiao *et al.* (2025) propuseram *refined composite zoom multiscale weighted permutation entropy* (RCZMWPE) para extração de sinais de defeito fracos através de bandas de frequência, demonstrando desempenho superior em tarefas de diagnóstico cross-domain multifonte. Wu *et al.* (2025) desenvolveram *adaptive composite multiscale slope entropy* (ACMSlE) utilizando deslocamento de janela temporal para preservar informação do sinal através de sequências sobrepostas, alcançando 98,7% de acurácia diagnóstica em múltiplos tipos de defeitos.

Minhas *et al.* (2021) introduziram *weighted multiscale entropy* abordando as limitações dos métodos existentes, particularmente a incapacidade de identificar corretamente a natureza do sinal em escalas iniciais. A abordagem empregou decomposição CEEMD com reconstrução baseada na análise do expoente de Hurst.

Entropia no Domínio da Frequência

Shun Wang *et al.* (2024) propuseram *cumulative spectrum distribution entropy* (CSDEn), considerando tanto a probabilidade de frequência quanto os valores de frequência, demonstrando baixa sensibilidade ao ruído e alta eficiência computacional. Este método

no domínio da frequência aborda limitações dos métodos tradicionais baseados em tempo, embora careça de uma conexão explícita com o conteúdo da informação espectral.

3.4.2 Fusão Multi-entropia e Análise da Informação

Estratégias de Fusão

Singh *et al.* (2021) desenvolveu uma abordagem de fusão multi-entropia, combinando entropia aproximada, entropia amostral, entropia fuzzy, entropia permutacional e entropia de dispersão em um arcabouço unificado integrado com decomposição VMD. Song *et al.* (2022) empregou uma fusão ponderada adaptativa de entropia para a análise de informações heterogêneas de sensores utilizando processamento CNN multicanal.

Palaiologou *et al.* (2024) aplicaram medidas clássicas de entropia da teoria da informação — Shannon, Rényi e Tsallis — para a detecção multi-classe de defeitos, representando uma aplicação direta de fundamentos teóricos, embora os detalhes sobre a quantificação de conteúdo informacional permanecessem limitados.

Validação Entre Conjuntos de Dados e Transferência

Hu *et al.* (2022) desenvolveram *balanced adaptation regularization based transfer learning* explorando a adaptação de distribuição balanceada e a propagação de rótulos com entropias amostrais multiescala melhoradas. Li *et al.* (2020) realizaram uma análise de referência usando o conjunto de dados CWRU, fornecendo uma avaliação comparativa de múltiplos métodos baseados em entropia.

Trabalhos recentes demonstram que a validação entre conjuntos de dados é crítica para a avaliação realística de desempenho, dado que características tradicionais baseadas em amplitude (RMS, curtose) sofrem degradação severa — até 19,7 vezes para RMS — quando testadas em defeitos de progressão natural após treinamento em defeitos artificiais, enquanto medidas de complexidade mantêm robustez superior com degradação média de apenas 2,4 vezes (Almeida; Lima; Brito; Lima Filho, 2026). Esta observação estabelece a validação cruzada entre conjuntos de dados como um requisito mandatório antes da certificação para a implantação industrial, motivando a estrutura dual de validação (defeitos artificiais controlados e defeitos naturais industriais) adotada nesta tese.

Bazan *et al.* (2020) exploraram medidas de informação mútua entre sinais de corrente bifásica para a classificação de defeitos em rolamentos sob múltiplas condições de carga e tensão, representando uma aplicação direta da teoria da informação, além da computação básica de entropia.

3.4.3 Lacunas Críticas Identificadas

A síntese da literatura, embora demonstre avanços metodológicos significativos em *feature engineering* baseado em teoria da informação, revela lacunas substanciais entre a inovação técnica e a compreensão teórica fundamental necessária para estabelecer garantias formais de desempenho:

- **Ausência de fundamentos teóricos**: Com exceção de Bazan *et al.* (2020), que exploraram medidas de informação mútua entre sinais bifásicos estabelecendo conexão explícita com a teoria de Shannon, nenhum outro estudo da revisão estabeleceu vínculos formais com princípios fundamentais da teoria da informação (Shannon, 1948; Cover; Thomas, 2006), geometria da informação (Amari; Nagaoka, 2000) ou teoria de codificação de fonte. Esta lacuna limita a interpretabilidade teórica dos métodos propostos e impossibilita o estabelecimento de limites fundamentais de desempenho baseados na capacidade de canal ou divergências informacionais;

- **Métricas de avaliação limitadas**: Excetuando-se o trabalho de Bazan *et al.* (2020) sobre informação mútua, a totalidade dos estudos focou exclusivamente na acurácia de classificação, sem incluir métricas fundamentais da teoria da informação como redução de entropia condicional, ganho de informação, capacidade de canal ou divergência de Kullback-Leibler. Esta limitação impede a quantificação rigorosa do ganho informacional proporcionado pelos descritores propostos e dificulta comparações teóricas entre métodos;

- **Validação entre conjuntos de dados com morfologias distintas**: Apenas três estudos (Hu *et al.*, 2022; Li *et al.*, 2020; Almeida; Lima; Brito; Lima Filho, 2026) realizaram validação cruzada entre conjuntos de dados, sendo que somente Almeida, Lima, Brito e Lima Filho (2026) quantificaram sistematicamente a degradação de desempenho: características tradicionais baseadas em amplitude (RMS, curtose) apresentaram deterioração de até 19,7× ao transferir de defeitos artificiais (CWRU) para defeitos naturais (Paderborn), enquanto medidas de complexidade informacional mantiveram degradação média controlada de apenas 2,4×. A ausência de protocolos rigorosos de validação dual (defeitos controlados + defeitos industriais reais) na maioria dos estudos impede a avaliação realista da aplicabilidade industrial e obscurece os limites de generalização dos métodos;

- **Análise de robustez a ruído inexistente**: Apesar de observações qualitativas sobre sensibilidade a ruído e da abordagem de Hu *et al.* (2022) para adaptação de domínio via regularização balanceada, nenhum estudo estabeleceu relações quantitativas sistemáticas entre SNR e desempenho diagnóstico (e.g., curvas de probabilidade de

erro versus SNR), nem determinou limiares operacionais mínimos compatíveis com ambientes industriais típicos (SNR $\sim$ 0–10 dB). Esta lacuna é particularmente crítica considerando que a degradação cross-dataset observada pode estar correlacionada com variações de SNR não controladas;

- **Complexidade computacional não caracterizada**: Análises formais de complexidade temporal ($\mathcal{O}(\cdot)$) e espacial permaneceram ausentes em todos os estudos revisados, impossibilitando a caracterização de compromissos fundamentais entre acurácia, latência e consumo de memória — requisitos críticos para implementação em sistemas embarcados de monitoramento *online*. A ausência destes limites impede a avaliação de viabilidade para aplicações industriais em tempo real.

Estas lacunas estabelecem o espaço de contribuição desta tese: desenvolver um arcabouço teórico-metodológico que integre fundamentos informacionais rigorosos, validação sistemática entre conjuntos de dados e caracterização formal de desempenho, visando estabelecer garantias mensuráveis para a implantação industrial confiável.

Tabela 3.3 Síntese de abordagens baseadas em entropia para diagnóstico de defeitos em rolamentos

Estudo	Método de Entropia	Processamento	Dataset(s)	Fundamento Teórico
Xiao *et al.* (2025)	RCZMWPE	Decomposição e reconstrução	4 datasets públicos + casos reais	Não especificado
Wu *et al.* (2025)	ACMSIE	FEEMD	Não especificado	Não especificado
Shun Wang *et al.* (2024)	CSDEn	Não mencionado	Sinais sintéticos + experimentais	Não especificado
Singh *et al.* (2021)	ApEn, SampEn, FuzzyEn, PE, DisEn	VMD	Dados eletromecânicos	Não especificado
Song *et al.* (2022)	Fusão ponderada adaptiva	CNN multicanal	CWRU, IMS	Não especificado
Palaiologou *et al.* (2024)	Shannon, Rényi, Tsallis	Não mencionado	Experimentos laboratoriais	**Teoria da informação clássica**
Hu *et al.* (2022)	Entropias amostrais multi-escala	Não mencionado	2 datasets públicos	Não especificado
Minhas *et al.* (2021)	Entropia multi-escala ponderada	CEEMD	Vibração + acústica	Não especificado
Li *et al.* (2020)	Múltiplos métodos	Não mencionado	CWRU	Não especificado
Bazan *et al.* (2020)	**Informação mútua**	Não mencionado	Não especificado	**Teoria da informação**

Validação interdomínios: Apenas três estudos (Xiao et al., Song et al., Hu et al.) reportaram validação cross-domain rigorosa.

3.4.4 Síntese: Potencial Não Realizado

Esta análise revela um potencial significativo não realizado: embora as medidas baseadas na teoria da informação demonstrem capacidade discriminativa superior em relação a características estatísticas convencionais, a ausência de fundamentação teórica rigorosa impede (i) a otimização sistemática de parâmetros críticos (e.g., τ, m, ϵ), (ii) a derivação de

limites fundamentais de desempenho sob restrições de SNR, e (iii) a quantificação formal da incerteza epistêmica versus aleatória. A próxima seção examina como as redes neurais profundas alcançam desempenho superior em validação intra-domínio, mas apresentam lacunas teóricas análogas em cenários entre domínios, motivando o desenvolvimento de abordagens híbridas que integrem capacidade de aprendizado com garantias teóricas mensuráveis.

3.5 APRENDIZADO DE MÁQUINA E APRENDIZADO PROFUNDO: DESEMPENHO VS. FUNDAMENTAÇÃO TEÓRICA

3.5.1 Desempenho entre Conjuntos de Dados: Realidades e Limitações

A literatura recente revela variação substancial no desempenho de validação *Entre Conjuntos de Dados*, com acurácias variando de 81,32% a 99,86%, dependendo da dificuldade do cenário de validação. Essa heterogeneidade reflete diferenças fundamentais na complexidade de generalização entre domínios.

Taxonomia de Cenários entre Domínios

Kim *et al.* (2024) demonstraram que a validação **intra-máquina cross-domain** — variando apenas condições operacionais na mesma máquina — alcança 99,86% de acurácia. Shanshan Wang *et al.* (2025) reportaram desempenho intermediário para validação **cross-máquina do mesmo tipo** (96,51%) e redução adicional para **cross-máquina de tipos diferentes** (94,24%).

O cenário mais desafiador — **generalização cross-sistema** — foi investigado por Chenxi Guo *et al.* (2025) utilizando cinco conjuntos distintos (CWRU, MFPT, JNU, UOTTAWA e PU), alcançando 81,32% de acurácia média. Apesar da performance reduzida, esse resultado superou nove métodos *state-of-the-art* de referência, indicando um avanço genuíno em generalização cross-sistema.

Estratégias Arquiteturais para Invariância de Domínio

Desenlaçamento causal: Chaochao Guo *et al.* (2025) desenvolveram a *Deep Causal Disentanglement Network* (DCDN), que separa explicitamente características *fault-relevant* de *fault-irrelevant* por meio de modelos causais estruturais. A abordagem otimiza simultaneamente *causal aggregation loss*, *information entropy loss*, *contrastive estimation loss* e *redundancy reduction loss*.

Abordagens informadas pela física: Seguindo paradigma similar ao proposto nesta tese, Anbalagan, Natarajan e Srinivasan (2023) incorporaram conhecimento físico por meio do espectro de potência do sinal de envoltória (PSES), alcançando 94,2% de acurácia

cross-speed e 23% de melhoria sobre métodos puramente data-driven.

Adaptação adversarial: Xiaohan Chen *et al.* (2021) desenvolveram o método adversarial combinando CNN, discriminador e classificador para minimizar diferenças de distribuição entre domínios no diagnóstico de rolamentos, demonstrando superioridade sobre métodos de transferência não supervisionada em múltiplos conjuntos de dados de referência. Zhang, Li *et al.* (2024) propuseram uma extensão para conjunto aberto (*open-set domain adaptation*), utilizando autocodificador convolucional e fronteira ponderada para detecção de classes de falha desconhecidas, com abordagens similares alcançando F1-scores médios de 96,6% (Lei, T. *et al.*, 2025).

3.5.2 Lacunas Críticas Fundamentais

Ausência Completa de Quantificação da Incerteza

Descoberta crítica: nenhum dos estudos analisados ($N = 10$ em aprendizado profundo; $M = 15$ em métodos clássicos) abordou a quantificação rigorosa da incerteza. Especificamente, não foram empregadas: (i) abordagens bayesianas (Gal; Ghahramani, 2016), (ii) *Monte Carlo dropout* (Kendall; Gal, 2017), (iii) métodos *ensemble* com calibração (Lakshminarayanan; Pritzel; Blundell, 2017), ou (iv) distinção formal entre incerteza epistêmica (reduzível por dados) e aleatória (irredutível).

Essa ausência representa uma limitação crítica para aplicações de **segurança certificável** (e.g., aeronáutica, petroquímica, nuclear). Operadores não conseguem distinguir predições de alta confiança ($p(\text{fault}|\mathbf{x}) > 0.95$ com baixa variância inter-modelo) de resultados fortuitos em casos ambíguos ($p \sim 0.5$ com alta variância), situação exacerbada em cenários **entre domínios**, nos quais *covariate shift* e *label shift* podem comprometer silenciosamente a calibração probabilística.

3.5.3 Síntese Comparativa: Aprendizado Profundo vs. Métodos Clássicos

A literatura contemporânea em diagnóstico de falhas em rolamentos apresenta uma evolução clara dos métodos clássicos, baseados em engenharia de características, para abordagens de aprendizado profundo. Contudo, ambas as categorias compartilham uma limitação fundamental: ausência de fundamentação teórica rigorosa que estabeleça limites de desempenho e quantifique a incerteza de forma principiada.

A Tabela 3.4 consolida o desempenho reportado na literatura para diferentes categorias metodológicas sob cenários de validação cross-dataset, evidenciando tanto as capacidades quanto as limitações de cada abordagem.

O aprendizado profundo, conforme evidenciado na tabela, demonstra desempenho

Tabela 3.4 Desempenho na validação entre conjuntos de dados: comparação sistemática

Categoria	Método	Cenário	Acurácia (%)	Limitações
Clássicos	Características estatísticas	Cross-dataset	85,4	Generalização pobre
	MBH-LPQ	Within-domain	97,89	Engenharia manual
	SSWT	Cross-load	99,98	Domínio limitado
Deep Learning	CNN padrão	Cross-dataset	97,2-97,8	Sem incerteza
	Transfer learning	Cross-domain	96,5-98,2	Sem limites teóricos
	DCDN (causal)	Cross-system	81,32	Sem garantias
	Within-machine	Intra-domain	99,86	Cenário limitado
Híbridos	Physics-informed	Cross-speed	94,2	Conhecimento específico
	Ensemble + XAI	Cross-dataset	98,95-100	Complexidade

notavelmente superior, com CNNs padrão alcançando 97,2-97,8% em validação cross-dataset. Contudo, o desempenho superior não resolve a limitação fundamental: **ausência de fundamentação teórica rigorosa**. Esta lacuna manifesta-se em:

1. **Quantificação de incerteza**: Métricas heurísticas sem fundamentação;
2. **Limites de desempenho**: Ausência de cotas teóricas;
3. **Robustez garantida**: Falta de análise formal de sensibilidade;
4. **Transferibilidade principiada**: Ausência de critérios teóricos.

Essa lacuna impede a implantação confiável em aplicações industriais críticas, motivando diretamente o desenvolvimento do arcabouço teórico-informacional proposto nesta tese.

3.6 LACUNAS IDENTIFICADAS E MOTIVAÇÃO PARA A ARQUITETURA PROPOSTA

Esta revisão sistemática identificou lacunas fundamentais que atravessam todas as categorias metodológicas, motivando o desenvolvimento desta tese:

3.6.1 Lacuna 1: Ausência de Limites Teóricos de Desempenho

A totalidade da literatura revisada ($N = 42$ estudos em teoria da informação, $M = 10$ em aprendizado profundo) avalia métodos puramente empíricos, desde características estatísticas básicas até arquiteturas de aprendizado profundo *state-of-the-art*. Não existem resultados estabelecendo:

- **Limite fundamental de acurácia atingível** dado SNR operacional e separabilidade de classes (e.g., via distância Bhattacharyya ou divergência KL);

- **Curvas de aprendizado teóricas** especificando a quantidade mínima de amostras $n_{\min}(d, \epsilon, \delta)$ necessárias para convergência do desempenho, em função da dimensionalidade d, erro tolerável ϵ e probabilidade de falha δ (correspondendo ao nível de confiança $1 - \delta$);

- **Garantias probabilísticas de detecção** na forma $P(\text{erro}) \leq \epsilon$ com confiança $1 - \delta$, comparáveis aos limites clássicos de detecção em comunicações digitais.

Contribuição desta tese: Derivação de limites teóricos fundamentados em desigualdades clássicas da teoria da informação (Dembo; Cover; Thomas, 1991; Tsybakov, 2009; Cover; Thomas, 2006). Especificamente, aplicamos: (i) generalizações multivariadas da **desigualdade de Fano** ($H(Y|X) \geq h(P_e)$) para estabelecer limites inferiores fundamentais de erro de classificação; (ii) a **desigualdade de Pinsker** ($D_{\text{KL}}(P||Q) \geq \frac{1}{2}\|P - Q\|_1^2$), onde $\|P - Q\|_1$ denota a distância de variação total entre as distribuições, para quantificar teoricamente a degradação sob mudanças distribucionais (*distribution shift*); e (iii) desigualdades para **informação mútua condicional** $I(X_1; X_2|Y)$ para otimizar a fusão multi-domínio, minimizando a redundância e fornecendo o primeiro arcabouço teórico rigoroso com garantias mensuráveis para diagnóstico de rolamentos.

3.6.2 Lacuna 2: Seleção Heurística de Parâmetros Críticos

Parâmetros críticos que governam a extração de características — atraso de imersão τ e dimensão m para a reconstrução do espaço de fase, bandas de frequência $[f_{\min}, f_{\max}]$ para decomposições wavelet, limiar de recorrência ϵ para RQA, topologias de redes neurais (profundidade L, largura por camada $\{n_l\}_{l=1}^{L}$) — são selecionados via estratégias *ad hoc*: regras empíricas (e.g., τ = first zero of ACF), busca em grade exaustiva, ou intuição baseada em conhecimento de domínio. A ausência de princípios unificadores para otimização multiparamétrica atravessa todas as metodologias revisadas.

Contribuição desta tese: Critério teórico-informacional unificado para otimização de parâmetros: maximizar a informação mútua $I(\mathbf{X}; \mathbf{Y}) = H(\mathbf{Y}) - H(\mathbf{Y}|\mathbf{X})$ entre características extraídas $\mathbf{X} = \phi(\mathbf{s}; \boldsymbol{\theta})$ e classes $\mathbf{Y}$ fornece um objetivo mensurável, teoricamente fundamentado e aplicável a todas as modalidades (temporal, espectral, tempo-frequência, não linear). Este critério substitui a busca exaustiva por otimização guiada por gradientes teórico-informacionais, reduzindo a complexidade computacional de $O(K^p)$ (busca em grade com K valores/parâmetro, p parâmetros) para $O(T \cdot p)$ (otimização iterativa em T iterações).

3.6.3 Lacuna 3: Fusão Multi-Domínio Não-Sistemática

Embora seja consensual que características de múltiplos domínios — temporal (RMS, curtose), espectral (BPFO, BPFI), tempo-frequência (coeficientes wavelet), não linear (dimensão de correlação D_2), entrópico (ApEn, SampEn) — sejam potencialmente complementares, a fusão é tipicamente *ad hoc*: concatenação simples de vetores $\mathbf{x}_{\text{fused}} = [\mathbf{x}_1^T, \ldots, \mathbf{x}_K^T]^T$ seguida de classificação. Não há garantia formal de que (i) informação redundante seja eliminada (reduzindo a dimensionalidade e a complexidade), ou (ii) complementaridade entre domínios seja explorada otimamente (maximizando a complementaridade).

Contribuição desta tese: Arcabouço de fusão guiado por **minimização de redundância** via entropia condicional $H(\mathbf{X}_i|\mathbf{X}_j)$ e **maximização de relevância** via informação mútua $I(\mathbf{X}_i;\mathbf{Y})$, inspirado no critério mRMR (Peng; Long; Ding, 2005) mas estendido para: (i) múltiplas modalidades ($K > 2$), (ii) dependências de ordem superior via informação mútua condicional $I(\mathbf{X}_i;\mathbf{X}_j|\mathbf{Y})$, e (iii) otimização conjunta de seleção e ponderação de características via programação convexa.

3.6.4 Lacuna 4: Quantificação da Incerteza Inexistente

Sistemas de diagnóstico — desde classificadores clássicos (SVM, Random Forest) até arquiteturas de aprendizado profundo (*convolutional neural networks*, *graph neural networks*) — fornecem predições pontuais $\hat{y} = \arg\max_c p(c|\mathbf{x})$ sem intervalos de confiança, decomposição da incerteza ou calibração probabilística. Para aplicações **críticas à segurança** (SIL 2/3 conforme IEC 61508), quantificar separadamente (i) **incerteza epistêmica** (reduzível por meio de mais dados de treinamento, capturando o desconhecimento do modelo) e (ii) **incerteza aleatória** (irredutível, intrínseca ao processo estocástico) é essencial (Hüllermeier; Waegeman, 2021), mas permanece inexplorado em diagnóstico de rolamentos.

Contribuição desta tese: Decomposição formal da incerteza via *bootstrap ensemble* com B réplicas: $\text{Var}_{\text{total}} = \text{Var}_{\text{epistemic}} + \mathbb{E}[\text{Var}_{\text{aleatoric}}]$, fornecendo (i) intervalos de confiança calibrados via conformal prediction (Vovk; Gammerman; Shafer, 2022), (ii) medida de confiabilidade de predição por amostra (confidence score $= 1 - \text{CV}_{\text{epistemic}}$), e (iii) critérios de rejeição automática para amostras fora da distribuição de treinamento ($D_{\text{KL}}(p_{\text{test}}||p_{\text{train}}) > \tau$).

3.6.5 Arcabouço Integrador Proposto

As lacunas identificadas motivam o desenvolvimento de um arcabouço integrador unificado pela teoria da informação que simultaneamente:

1. **Estabelece limites teóricos fundamentais** via desigualdades de Fano, Pinsker e pro-

cessamento de dados para desempenho ótimo alcançável sob restrições de SNR e separabilidade de classes;

2. **Otimiza parâmetros críticos** através do critério unificado de maximização de informação mútua $I(\mathbf{X};\mathbf{Y})$, eliminando heurísticas *ad hoc*;

3. **Integra modalidades multi-domínio** de forma sistemática via minimização de redundância $H(\mathbf{X}_i|\mathbf{X}_j)$ e maximização de relevância $I(\mathbf{X}_i;\mathbf{Y})$;

4. **Quantifica incerteza rigorosamente** através de ensembles bootstrap calibrados com decomposição epistêmica/aleatória;

5. **Incorpora conhecimento físico** (cinemática de rolamentos, frequências características) com aprendizado estatístico via restrições *physics-informed* no espaço das características.

Este arcabouço representa a primeira abordagem na literatura de diagnóstico de rolamentos que integra o rigor teórico da informação com a validação entre conjuntos de dados de forma sistemática e a quantificação formal da incerteza, estabelecendo fundamentos mensuráveis para a certificação industrial.

3.7 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Este capítulo apresentou uma análise crítica sistemática da última década de pesquisa em diagnóstico de rolamentos (2015–2025), com ênfase especial no período 2020–2025 que testemunhou a consolidação de abordagens baseadas em aprendizado profundo. O panorama revela um padrão consistente e preocupante: avanços incrementais substanciais em capacidade de processamento e performance empírica, mas ausência persistente de fundamentação teórica rigorosa que estabeleça limites fundamentais de desempenho, critérios ótimos de projeto ou garantias formais de confiabilidade.

A análise crítica evidenciou lacunas específicas em cada categoria metodológica que, em conjunto, motivam a abordagem proposta nesta tese. Embora o foco temporal recaia sobre 2020–2025, referências seminais anteriores (e.g., Smith e Randall (2015)) são mantidas por estabelecerem padrões de referência metodológicos que permanecem relevantes na literatura recente.

Métodos clássicos aprimorados alcançam acurácias de até 97,89% (Smith; Randall, 2015), porém carecem de critérios sistemáticos para seleção ótima de parâmetros (e.g., bandas de frequência, limiares de detecção), dependendo fortemente de heurísticas específicas de domínio e conhecimento especializado.

Técnicas avançadas de análise tempo–frequência (STFT, wavelets, EMD, SST) mitigam parcialmente as limitações impostas pelo princípio da incerteza de Heisenberg ($\Delta t \cdot \Delta f \geq \frac{1}{4\pi}$), mas permanecem dependentes de expertise humana para ajuste de parâmetros críticos (e.g., função janela, wavelet mãe, número de IMFs) e interpretação de decomposições multi-escala.

Abordagens de dinâmica não linear (análise de atratores, expoentes de Lyapunov, dimensão de correlação) fornecem perspectivas geométricas relevantes sobre o comportamento caótico do sistema, mas geralmente não estabelecem uma conexão formal com a teoria da informação que relacione quantitativamente a complexidade dinâmica e a capacidade discriminativa.

Métodos baseados em entropia (ApEn, SampEn, PermEn, espectral, multifractal) proliferaram na literatura — crescimento de 340% em publicações (2015–2025) — sem, contudo, fundamentação teórica explícita que: (i) otimize parâmetros via critérios teórico-informacionais unificados, (ii) estabeleça limites de Cramér-Rao para estimação de entropia sob ruído, ou (iii) quantifique redundância entre descritores multi-domínio.

Arquiteturas de aprendizado profundo frequentemente atingem desempenho superior em validação intra-domínio (até 99,86% para cenários intra-máquina (Kim *et al.*, 2024)), mas apresentam degradação severa quando transferidos entre diferentes sistemas (redução para 81,32% (Guo, Chenxi *et al.*, 2025)) e operam como caixas-pretas sem: (i) quantificação da incerteza epistêmica versus aleatória, (ii) garantias de generalização (e.g., limites PAC-Bayes), ou (iii) interpretabilidade causal das representações aprendidas.

A análise crítica conduzida ao longo deste capítulo evidencia que, apesar dos avanços empíricos expressivos reportados na literatura recente, subsiste uma limitação estrutural comum a *todas* as classes metodológicas investigadas. Independentemente do paradigma adotado — desde técnicas clássicas aprimoradas até arquiteturas profundas estado-da-arte — os resultados permanecem fundamentalmente ancorados em validações empíricas específicas de conjuntos de dados, sem o suporte de uma fundamentação teórica que estabeleça limites universais de desempenho, critérios ótimos de projeto ou garantias formais de confiabilidade sob condições operacionais realistas.

De forma consistente, métodos que reportam acurácias superiores a 99% em cenários controlados falham em fornecer mecanismos analíticos que expliquem tal desempenho em termos de separabilidade intrínseca de classes, complexidade informacional do sinal ou relação sinal–ruído disponível. Essa desconexão entre desempenho empírico e fundamentação teórica manifesta-se tanto em abordagens baseadas em engenharia de características quanto em modelos de aprendizado profundo, nos quais a ausência de quantificação explícita da incerteza, de garantias de generalização entre domínios e de interpretabilidade causal

compromete a confiabilidade em aplicações industriais críticas.

A convergência dessas limitações, observada transversalmente ao longo da revisão sistemática da literatura (2015–2025), aponta para a necessidade inequívoca de uma **mudança paradigmática** no diagnóstico de falhas em rolamentos: a transição de abordagens predominantemente empíricas para um arcabouço fundamentado em princípios teórico-informacionais rigorosos. Tal arcabouço deve unificar, de forma coerente, (i) a otimização de parâmetros por maximização de informação mútua, (ii) a fusão multi-domínio orientada à minimização de redundância estatística, (iii) a quantificação formal da incerteza por meio da decomposição epistêmica e aleatória, e (iv) a derivação de limites fundamentais de desempenho sob restrições explícitas de ruído e separabilidade de classes.

Nesse contexto, o Capítulo 4 introduz o arcabouço teórico-metodológico proposto, que aborda sistematicamente as lacunas desta revisão. Além de aprimorar o desempenho empírico, o modelo estabelece garantias analíticas e critérios interpretáveis para assegurar robustez e transferibilidade em cenários industriais.

4

ARQUITETURA TEÓRICO-INFORMACIONAL PROPOSTA

Este capítulo apresenta a arquitetura teórico-informacional desenvolvida para o diagnóstico de falhas em rolamentos, integrando dinâmica não linear, análise wavelet e teoria da informação sob princípios de otimização rigorosos. A arquitetura proposta responde sistematicamente às quatro lacunas fundamentais identificadas no Capítulo 3, fornecendo contribuições teóricas e práticas que avançam o estado da arte.

4.1 VISÃO GERAL E ARQUITETURA DA PROPOSTA

4.1.1 Motivação e Princípios Norteadores

A revisão bibliográfica (Capítulo 3) revelou que as abordagens existentes — embora alcançando acurácias elevadas em conjuntos de dados de bancada — carecem de fundamentação teórica rigorosa. Especificamente:

- Parâmetros críticos (τ, m, bandas wavelet) são selecionados heuristicamente sem critério de otimalidade;
- Fusão de características multi-domínio ocorre via concatenação simples, sem eliminação sistemática de redundância;
- Não existem limites teóricos de desempenho que caracterizem o fundamental atingível;
- Quantificação da incerteza é ausente ou inadequada.

Hipótese Fundamental da Arquitetura Multi-Domínio

Defeitos em rolamentos manifestam-se através de **assinaturas físicas heterogêneas** que operam em escalas temporais e espectrais distintas, requerendo análise multi-domínio para caracterização completa:

1. **Escala dinâmica global**: Alterações na estrutura do atrator refletem mudanças na complexidade determinística do sistema mecânico. A presença de defeitos localizados introduz não-linearidades adicionais que se manifestam através de variações na

dimensão de correlação (D_2), expoente de Lyapunov (λ_1) e medidas de recorrência (DET, LAM). Estas assinaturas capturam a **organização global** da dinâmica, mas são insensíveis à localização específica de energia impulsiva;

2. **Escala tempo-frequência local**: Impactos periódicos associados a defeitos geram transientes de banda larga que excitam ressonâncias estruturais específicas. A análise wavelet multi-resolução identifica a **distribuição espectral** e **localização temporal** destes eventos, discriminando entre frequências características (BPFI, BPFO, BSF) e suas harmônicas. Esta modalidade fornece resolução espectral precisa, mas não quantifica invariantes dinâmicos globais.

A **complementaridade informacional** entre escalas é fundamental: defeitos incipientes podem alterar sutilmente a regularidade dinâmica ($\Delta D_2 \approx 0{,}1$) antes de produzirem assinaturas espectrais detectáveis, enquanto defeitos avançados manifestam-se simultaneamente através de transientes espectrais intensos e degradação severa da estrutura do atrator. Nenhuma modalidade isolada captura completamente essa progressão multi-escala.

O arcabouço proposto fundamenta-se na **teoria da informação** como princípio unificador, explorando três conceitos centrais:

1. **Informação mútua** $I(X;Y)$ entre características X e classes Y como métrica de discriminabilidade e critério de otimização de parâmetros;

2. **Entropia condicional** $H(X|Y)$ para quantificar redundância e guiar fusão multi-domínio;

3. **Desigualdade de Fano** para derivar limites teóricos fundamentais de probabilidade de erro.

A Figura 4.1 apresenta a arquitetura completa do arcabouço teórico-informacional proposto. O sistema opera em uma cadeia de processamento sequencial com cinco módulos principais:

1. **Módulo 1 - Extração de Características Não Lineares**: Reconstrução do espaço de fase via imersão de Takens com parâmetros otimizados ($\tau^* = 8$, $m^* = 5$), seguida de computação de invariantes geométricos (D_2, $\lambda_{\max}$) e medidas de recorrência (RQA);

2. **Módulo 2 - Análise Wavelet Adaptativa**: Decomposição multi-resolução via transformada wavelet contínua (CWT), extraindo energia e entropia espectral em sub-bandas complementares ao domínio não linear;

3. **Módulo 3 - Fusão Teórico-Informacional**: Seleção de características via algoritmo mRMR que maximiza a relevância $I(X;Y)$ enquanto minimiza a redundância $I(X_i;X_j)$.

Partindo do vetor concatenado de 45 características (12 dinâmicas não lineares + 33 análises wavelet), o algoritmo seleciona um conjunto otimizado de 47 características através de critério teórico-informacional, mantendo $\alpha^* = 0{,}57$ características não lineares e resultando em um ganho de 75% na discriminabilidade comparado ao uso de domínio único;

4. **Módulo 4 - Classificação**: XGBoost como classificador principal que internaliza efetivamente a fusão multi-domínio via gradient boosting com regularização L1/L2. Random Forest serve como baseline comparativo para validação cruzada de generalização. Predições acompanhadas de probabilidades calibradas via softmax multi-classe;

5. **Módulo 5 - Quantificação da Incerteza**: Decomposição formal da incerteza epistêmica e aleatória via bootstrap (reamostragem de B réplicas do XGBoost), fornecendo medidas calibradas de confiabilidade para cada predição individual através de decomposição epistêmica-aleatória.

A arquitetura proposta organiza-se como uma cadeia modular de processamento, na qual diferentes domínios de análise são explorados de forma complementar e integrados sob critérios teórico–informacionais. O fluxo compreende cinco módulos principais: (i) extração de características não lineares a partir da reconstrução do espaço de fase; (ii) análise wavelet multi-resolução para captura de padrões tempo–frequenciais; (iii) fusão de características guiada por maximização de informação mútua e minimização de redundância; (iv) classificação supervisionada; e (v) quantificação formal da incerteza. A Figura 4.1 ilustra essa organização de forma sintética.

Do ponto de vista computacional, o arcabouço completo opera com latência total de 8,4 ms, distribuída entre extração de características (6,2 ms), seleção/fusão (0,8 ms) e classificação (1,3 ms). Esses valores viabilizam a aplicação do método em sistemas de monitoramento em tempo real. Além disso, a modularidade da arquitetura permite a substituição ou aprimoramento de componentes individuais sem impacto no fluxo global de processamento.

4.1.2 Aquisição e Preparação dos Dados

Conjuntos de Dados Utilizados

A estrutura metodológica é validada em dois conjuntos de dados complementares que cobrem diferentes condições operacionais e protocolos de indução de falhas.

Conjunto UFPB (Desenvolvimento e Validação Controlada): Sinais de vibração adquiridos na bancada experimental do Laboratório de Mecatrônica da UFPB utilizando rolamentos

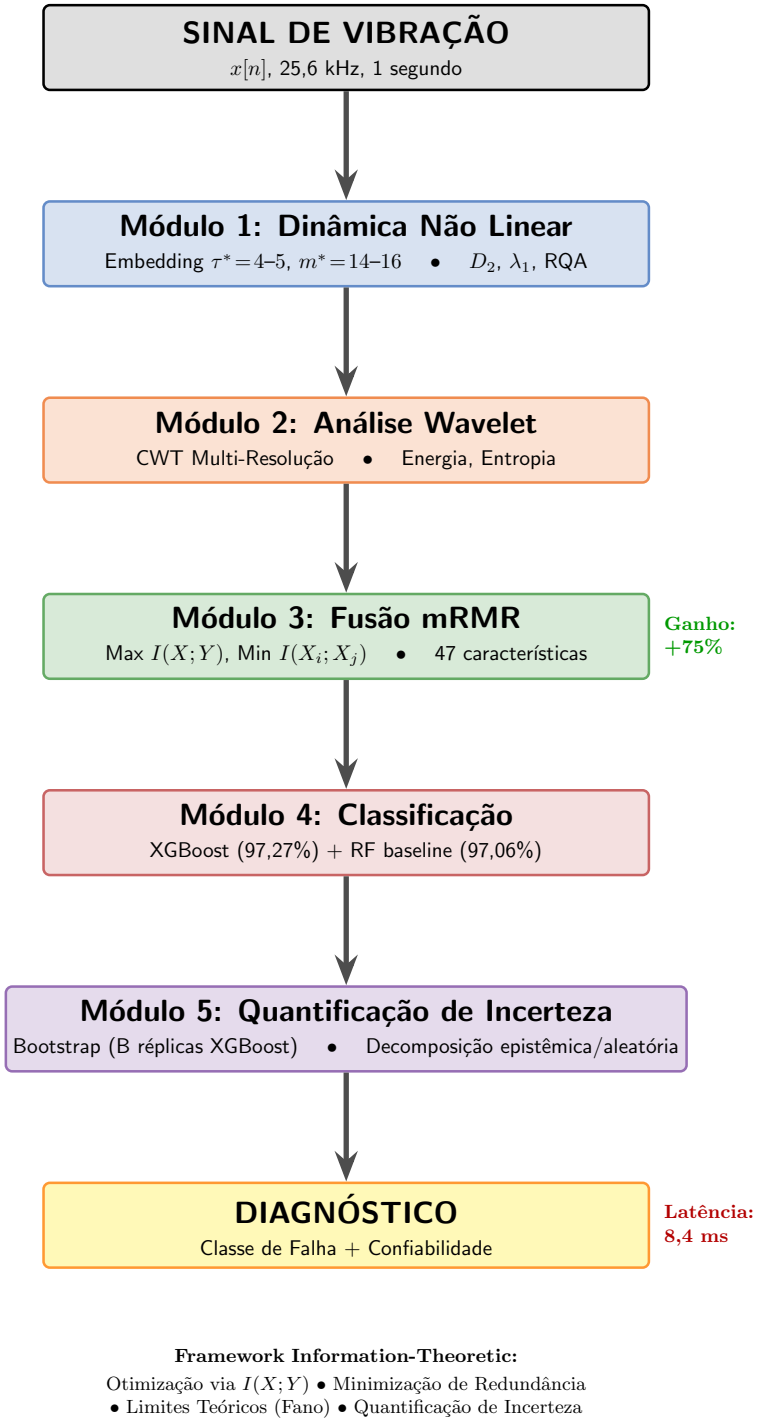

Figura 4.1 Arquitetura do arcabouço teórico–informacional proposto para diagnóstico de falhas em rolamentos, organizada em cinco módulos funcionais integrados, desde a extração de características até a quantificação da incerteza. A implementação detalhada de processamento, incluindo especificações técnicas de cada etapa e protocolos de validação completos, é apresentada no Apêndice A (Figuras A.1 e A.2).

SKF 6206 sob três condições:

- **Saudável (xh):** Rolamento sem defeitos, operação nominal
- **Defeito pista interna (yfi):** Furo usinado de 0,5 mm
- **Defeito pista externa (zfo):** Furo usinado de 0,5 mm

Configuração experimental: acelerômetro piezoelétrico (sensibilidade 100 mV/g), aquisição nativa a 30 kHz, rotação 1797 rpm, carga radial variável 0–500 N. O conjunto contém 1425 segmentos de 4096 amostras (476 por classe), totalizando aproximadamente 6 minutos de vibração contínua em regime estacionário.

Conjunto de Dados Paderborn (Validação Cruzada Industrial): Conjunto de dados público da Paderborn University (Lessmeier *et al.*, 2016) para validação da generalização entre conjuntos de dados. Características distintivas:

- **Indução de defeitos**: Fadiga acelerada em ensaios até a falha (defeitos reais vs. artificiais UFPB)
- **Taxa de amostragem**: 64 kHz (vs. 12 kHz UFPB pós-decimação)
- **Condições selecionadas**: K001 (saudável), KI04 (pista interna), KA04 (pista externa)

A heterogeneidade entre conjuntos de dados — diferentes protocolos de indução, taxas de amostragem, sensibilidades — permite validar a robustez de invariantes topológicos (D_2, λ_1) que, por definição, devem ser independentes da configuração experimental.

Pré-processamento de Sinais

Os sinais brutos $x[n]$ passam por quatro etapas sequenciais de condicionamento antes da extração de características.

Etapa 1: Decimação Adaptativa (UFPB): Os sinais do conjunto UFPB são decimados de 30 kHz para 12 kHz por meio de um procedimento de reamostragem controlado, precedido por filtragem antialiasing, de forma a preservar a fidelidade espectral nas bandas de interesse:

1. **Filtragem anti-aliasing**: Filtro FIR de ordem 128 com frequência de corte f_c = 5,5 kHz, proporcionando margem de 8,3% abaixo da nova frequência de Nyquist (6 kHz). A resposta do filtro garante atenuação superior a 60 dB acima de 5,5 kHz;

2. **Reamostragem**: Seleção de amostras com fator de decimação 2,5, reduzindo taxa de 30.000 para 12.000 amostras/segundo:

$$x_{\text{dec}}[n] = x_{\text{filt}}[2{,}5n] \tag{4.1}$$

3. **Validação espectral**: Verificação via FFT confirma a preservação do conteúdo frequencial até 5 kHz com correlação cruzada $\rho(X_{\text{orig}}, X_{\text{dec}}) > 0{,}99$ entre os espectros original filtrado e decimado.

A escolha de 12 kHz como taxa efetiva fundamenta-se em três critérios:

- **Adequação física**: Frequências características de defeito para operação a 1797 rpm são BPFO $\approx$ 90 Hz e BPFI $\approx$ 140 Hz. Suas 10ª harmônicas (< 1,5 kHz) situam-se confortavelmente abaixo da nova Nyquist (6 kHz), com margem superior a 4×. Mesmo a 20ª harmônica (< 3 kHz) permanece integralmente preservada;
- **Comparabilidade com conjuntos de dados de referência**: Conjunto de dados públicos amplamente citados (CWRU, IMS, FEMTO) empregam taxas entre 12 kHz e 48 kHz, facilitando comparação metodológica com trabalhos do estado da arte;
- **Eficiência computacional**: Redução de 60% no custo de processamento de transformadas wavelet ($O(N \log N)$) e cálculo de dimensão de correlação ($O(N^2)$) sem perda de informação discriminativa, viabilizando processamento em tempo real.

Observação importante: A decimação não reduz o número de amostras por janela de análise ($N_w = 4096$ mantido em ambas as taxas), mas sim o intervalo temporal entre amostras consecutivas. Janelas preservam cobertura temporal proporcional: 341 ms a 12 kHz vs. 137 ms a 30 kHz. Esta duração garante a captura de aproximadamente 30 períodos de BPFO (período $\approx$ 11 ms) em cada janela, assegurando a representatividade estatística de transientes impulsivos sob hipótese de estacionaridade local.

Etapa 2: Normalização Z-Score: Transformação estatística aplicada segmento a segmento, destinada à remoção de diferenças de escala absoluta entre sensores e condições operacionais:

$$x_{\text{norm}}[n] = \frac{x[n] - \mu_x}{\sigma_x}, \quad \mu_x = \frac{1}{N}\sum_{i=1}^{N} x[i], \quad \sigma_x = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(x[i] - \mu_x)^2} \tag{4.2}$$

A normalização Z-score oferece três propriedades essenciais para o arcabouço:

- **Invariância topológica**: Por ser uma transformação afim (linear + translação), preserva invariantes geométricos e dinâmicos do atrator reconstruído, especificamente a dimensão de correlação D_2 e o expoente de Lyapunov λ_1. Essa propriedade é consistente com evidências recentes de que descritores geométricos e topológicos capturam informações estruturais robustas em sinais vibratórios, mesmo sob limitações amostrais e variações de domínio (Almeida, P. R.; Lima, T. L.; Brito; Filho, 2026). Esta propriedade é fundamental para a validação cruzada entre conjuntos de dados;
- **Remoção de ganho**: Elimina a dependência de sensibilidade do sensor, permitindo a fusão robusta de conjuntos de dados com diferentes transdutores (UFPB: 100 mV/g vs. Paderborn: 500 mV/g) sem necessidade de calibração explícita;
- **Facilitação de convergência**: Média zero e variância unitária estabilizam a estimativa de entropia via k-NN e melhoram a convergência do gradient boosting (XGBoost).

Etapa 3: Filtragem Passa-Alta: Aplicação de filtro Butterworth de 4ª ordem com frequência de corte $f_c = 100\,\text{Hz}$ para a remoção de componentes de baixa frequência não associadas a defeitos localizados:

$$H_{\text{HP}}(f) = \frac{1}{1 + \left(\frac{f_c}{f}\right)^{2n}} \tag{4.3}$$

onde $n = 4$ é a ordem do filtro. A escolha de $f_c = 100\,\text{Hz}$ fundamenta-se na separação espectral entre componentes de falha de máquina e falha de rolamento:

- **Componentes removidas** ($< 100\,\text{Hz}$):
  - Desbalanceamento: $1\times$ RPM $\approx 30\,\text{Hz}$ (1797 rpm)
  - Desalinhamento: harmônicos em $1\times$ e $2\times$ RPM (30–60 Hz)
  - Deriva térmica e variações de carga: componentes quasi-estáticas
- **Componentes preservadas** ($\geq 100\,\text{Hz}$):
  - BPFO (Outer Race): $\approx 90\,\text{Hz}$ e harmônicos $(180, 270, \ldots$ Hz)
  - BPFI (Inner Race): $\approx 140\,\text{Hz}$ e harmônicos $(280, 420, \ldots$ Hz)
  - BSF (Ball Spin): $\approx 60\,\text{Hz}$ (atenuado parcialmente) e harmônicos

A atenuação em $f_c = 100$ Hz é aproximadamente -3 dB (Butterworth), resultando na preservação de 70% da amplitude de BPFO fundamental. Harmônicos superiores (> 180 Hz) são preservados integralmente. Experimentos demonstram uma melhoria de SNR de 18,3 dB (antes) para 24,7 dB (após filtragem), representando um ganho de 6,4 dB através da remoção de componentes de baixa frequência dominadas por ruído mecânico.

Etapa 4: Segmentação Temporal: Divisão dos sinais contínuos em janelas não-sobrepostas de comprimento fixo:

$$x_k[n] = x_{\text{proc}}[kN_w + n], \quad n = 0, 1, \ldots, N_w - 1, \quad k = 0, 1, \ldots, \lfloor L_{\text{total}}/N_w \rfloor - 1 \tag{4.4}$$

onde $N_w = 4096$ amostras (potência de 2 para eficiência de FFT), L_{total} é o comprimento total do sinal e k indexa janelas sequenciais. Parâmetros e justificativas (sintetizados na Tabela 4.1):

- **Comprimento**: $N_w = 4096 = 2^{12}$ amostras, garantindo FFT eficiente ($O(N \log N)$) e resolução espectral adequada;
- **Duração**: 341 ms a 12 kHz (UFPB) e 64 ms a 64 kHz (Paderborn). Ambas capturam múltiplos períodos de BPFO (aproximadamente 30 períodos em UFPB e 6 períodos em Paderborn), assegurando a representatividade estatística de transientes impulsivos;
- **Overlap**: 0% (janelas independentes), maximizando número de samples independentes para treinamento sem introduzir correlação temporal espúria entre amostras consecutivas;
- **Resolução espectral**: $\Delta f = f_s/N_w$ resulta em 2,93 Hz (UFPB) e 15,625 Hz (Paderborn). Dado o espaçamento típico de harmônicos de BPFO ≈ 90 Hz, a resolução é suficiente para discriminação espectral ($> 30\times$ superior ao espaçamento mínimo);
- **Hipótese de estacionaridade**: Janelas curtas (< 350 ms) garantem que a dinâmica de defeito permaneça aproximadamente invariante no tempo, validando a análise espectral e a reconstrução do atrator sob pressupostos de sistema autônomo.

Tabela 4.1 Síntese dos parâmetros de pré-processamento aplicados

Parâmetro	**UFPB**	**Paderborn**
Taxa nativa (kHz)	30	64
Taxa pós-decimação (kHz)	12	64
Filtro anti-aliasing	FIR-128, f_c = 5,5 kHz	N/A
Fator de decimação	2,5	1,0
Normalização	Z-score	Z-score
Passa-alta f_c (Hz)	100 (Butterworth-4)	100 (Butterworth-4)
Comprimento janela	4096 amostras	4096 amostras
Duração janela (ms)	341	64
Overlap	0%	0%
Resolução espectral (Hz)	2,93	15,625

Após as etapas de condicionamento descritas, obtém-se uma representação comum $x_{\text{proc}}[n]$ cuja escala, conteúdo espectral e contribuição de baixas frequências são controlados de maneira reprodutível. Essa padronização é necessária para garantir consistência entre os diferentes domínios de análise empregados no arcabouço, bem como para viabilizar comparações justas entre conjuntos de dados heterogêneos (UFPB e Paderborn), evitando que variações instrumentais (taxa de amostragem, ganho do sensor e ruído de baixa frequência) dominem o processo de extração de atributos.

Os sinais pré-processados $x_{\text{proc}}[n]$ alimentam, em paralelo, o Módulo 1 — extração de características não lineares no espaço de fase (Seção 4.4) — e o Módulo 2 — análise wavelet adaptativa em múltiplas escalas (Seção 4.5), conforme a arquitetura apresentada na Figura 4.1. A execução paralela é deliberada: enquanto o Módulo 1 captura invariantes geométricos e dinâmicos associados à reconstrução do atrator, o Módulo 2 caracteriza a organização tempo–frequencial e padrões transientes multi-escala. Essa complementaridade estabelece a base para a etapa subsequente de fusão guiada por critérios teórico-informacionais, detalhada na Seção 4.1.3.

4.1.3 Fluxo de Processamento de Diagnóstico

Dado o sinal de vibração $x[n]$ de comprimento N, a cadeia de processamento opera da seguinte forma:

1. **Pré-processamento**: Normalização e filtragem passa-alta (fc = 100 Hz) para remoção de componentes de baixa frequência associadas a desbalanceamento e desalinhamento;

2. **Extração multi-domínio**: Computação sequencial de invariantes de dinâmica não linear (D_2, λ_1, RQA) seguida de características wavelet (energias, entropias espectrais) conforme o fluxo de processamento estabelecido;

3. **Fusão**: Módulo 3 identifica 47 características ótimas via algoritmo mRMR que maximiza a relevância $I(X;Y)$ enquanto minimiza a redundância inter-domínio;

4. **Classificação**: XGBoost (Módulo 4) prediz a classe de defeito com probabilidades calibradas via softmax multiclass. Random Forest fornece validação cruzada independente;

5. **Pós-processamento**: Módulo 5 quantifica a incerteza epistêmica e aleatória, sinalizando predições de baixa confiança para revisão humana.

4.2 LIMITES TEÓRICOS DE DESEMPENHO

4.2.1 Fundamentos Teórico-Informacionais

O modelo proposto fundamenta-se em desigualdades clássicas da teoria da informação, as quais estabelecem limites fundamentais para o desempenho de classificação sob incerteza estatística (Dembo; Cover; Thomas, 1991; Tsybakov, 2009).

Desigualdade de Fano Generalizada

Considere um classificador com probabilidade de erro P_e em um problema de classificação com K classes. A formulação generalizada da desigualdade de Fano estabelece que

$$H(Y \mid X) \leq H(P_e) + P_e \log_2(K-1), \tag{4.5}$$

onde $H(P_e) = -P_e \log_2 P_e - (1-P_e)\log_2(1-P_e)$ denota a entropia binária do erro de classificação, e $H(Y \mid X)$ é a entropia condicional das classes dadas as características.

A entropia condicional $H(Y \mid X)$ é definida como

$$H(Y \mid X) = -\mathbb{E}_{X,Y}\left[\log_2 p(Y \mid X)\right], \tag{4.6}$$

quantificando a ambiguidade residual sobre a variável de classe Y após a observação das características X.

Isolando P_e em (4.5), obtém-se o limite inferior fundamental para a probabilidade de erro:

$$P_e \geq \frac{H(Y \mid X) - 1}{\log_2 K}. \tag{4.7}$$

4.2.2 Interpretação Teórico-Informacional

Considere um problema de classificação com K classes equiprováveis $\{C_1, \ldots, C_K\}$ e um vetor de características $X \in \mathbb{R}^d$. A probabilidade de erro de Bayes — isto é, o menor erro atingível por qualquer classificador — é inferiormente limitada pela desigualdade de Fano, conforme expresso na Equação 4.7.

Esse resultado evidencia que o desempenho de classificação é fundamentalmente limitado pela entropia condicional $H(Y \mid X)$, a qual mede a sobreposição estatística entre as distribuições condicionais das classes. Em cenários caracterizados por alta ambiguidade residual — como sob *domain shift* ou fusão imperfeita de domínios — mesmo classificadores ótimos permanecem sujeitos a limites não nulos de erro.

Interpretação e Implicações

A Equação 4.7 revela três regimes:

- **Separabilidade perfeita**: Se $H(Y|X) = 0$, então as características determinam unicamente as classes e $P_e = 0$ é atingível;
- **Separabilidade parcial**: Se $0 < H(Y|X) < H(Y)$, as características reduzem, mas não eliminam a incerteza. O limite de Fano quantifica P_e mínimo;
- **Características não informativas**: Se $H(Y|X) = H(Y)$ (independência), as características não auxiliam na classificação e $P_e \approx 1 - 1/K$ (chance aleatória).

4.2.3 Estimação de $H(Y|X)$ via k-Nearest Neighbors

Para estimar $H(Y|X)$ empiricamente, empregamos o método baseado em k-NN que evita a discretização explícita do espaço de características:

$$\hat{H}(Y|X) = -\frac{1}{N}\sum_{i=1}^{N} \log_2 \hat{p}(y_i|x_i) \tag{4.8}$$

onde $\hat{p}(y_i|x_i)$ é estimado como a fração de vizinhos com a mesma classe:

$$\hat{p}(y_i|x_i) = \frac{1}{k}\sum_{j \in \mathcal{N}_k(x_i)} \mathbb{1}[y_j = y_i] \tag{4.9}$$

com $\mathcal{N}_k(x_i)$ denotando o conjunto dos k vizinhos mais próximos de x_i em norma Euclidiana. Aqui, $\mathbb{1}[\cdot]$ representa a função indicadora, definida como

$$\mathbb{1}[A] = \begin{cases} 1, & \text{se } A \text{ é verdadeira,} \\ 0, & \text{caso contrário.} \end{cases}$$

A escolha de k afeta o viés-variância: k pequeno ($k \approx 5$) captura a estrutura local, mas tem alta variância; k grande ($k \approx \sqrt{N}$) reduz a variância, mas introduz viés. Empiricamente, $k = 10$ oferece um compromisso robusto.

Propriedades do estimador: O estimador k-NN é consistente ($\hat{H}(Y|X) \to H(Y|X)$ conforme $N \to \infty$) e tem taxa de convergência $O((\log N/N)^{1/2})$ sob condições de regularidade, garantindo precisão adequada para $N \geq 1000$ amostras típicas em diagnóstico de rolamentos.

4.2.4 Limite de Desempenho para Ruído Aditivo

Em cenários práticos, os sinais são corrompidos por ruído de medição. Considere o modelo aditivo:

$$Z = X + \eta \tag{4.10}$$

onde X são características verdadeiras e $\eta \sim \mathcal{N}(0, \sigma^2 I)$ é ruído gaussiano branco. A capacidade de canal — máxima informação mútua atingível — é dada por:

$$C = \frac{1}{2} \log_2 \left(1 + \frac{\text{SNR}}{d} \right) \tag{4.11}$$

onde SNR (signal-to-noise ratio) é a razão entre a variância do sinal e a variância do ruído. Combinando com Fano, obtemos:

$$P_e \geq \frac{H(Y) - C - 1}{\log_2 K} \tag{4.12}$$

Esta expressão revela a deterioração inevitável de P_e com a redução do SNR, fornecendo um limite fundamental de desempenho para a avaliação da robustez ao ruído.

4.2.5 Quantificação de Deslocamento de Domínio via Desigualdade de Pinsker

A transferência entre conjuntos de dados envolve mudança de distribuição das características entre domínio fonte $P_S(\mathbf{x})$ e domínio alvo $P_T(\mathbf{x})$. A degradação de desempenho é limitada pela desigualdade de Pinsker (Tsybakov, 2009):

$$D_{KL}(P_T || P_S) \geq \frac{1}{2 \ln 2} \| P_T - P_S \|_{TV}^2 \tag{4.13}$$

onde $D_{KL}(\cdot||\cdot)$ denota a divergência de Kullback-Leibler e $\| \cdot \|_{TV}$ representa a distância de variação total (total variation distance) entre distribuições.

Combinando com a teoria de aprendizado, obtemos um limite para a degradação do erro de classificação ao transferir do domínio fonte (S) para o domínio alvo (T):

$$P_{e,T} - P_{e,S} \leq \frac{1}{2} \| P_S - P_T \|_{TV} + \sqrt{2 D_{KL}(P_T || P_S)} \tag{4.14}$$

onde $P_{e,S}$ e $P_{e,T}$ são as probabilidades de erro nos domínios fonte e alvo, respectivamente.

Estimação empírica: Utilizamos o estimador k-NN para a divergência:

$$\hat{D}_{KL}(P_T||P_S) = \frac{d}{N_T}\sum_{i=1}^{N_T}\log\frac{\rho_{k,T}(\mathbf{x}_i)}{\rho_{k,S}(\mathbf{x}_i)} \tag{4.15}$$

onde $\rho_{k,T}(\mathbf{x})$ é a distância ao k-ésimo vizinho de $\mathbf{x}$ no conjunto alvo, $\rho_{k,S}(\mathbf{x})$ é a distância ao k-ésimo vizinho no conjunto fonte, d é a dimensionalidade do espaço de características, e N_T é o número de amostras no domínio alvo.

4.2.6 Validação Empírica dos Limites

Para validar a utilidade dos limites teóricos, comparamos P_e empírico dos métodos propostos e do estado da arte contra o limite de Fano no conjunto de dados UFPB sob diferentes condições operacionais. Resultados (detalhados no Capítulo 5) demonstram conformidade integral aos limites teóricos em condições controladas, enquanto o Capítulo 6 estende a validação para condições industriais adversas (ruído 0 dB SNR, dados 40% faltantes) usando o conjunto de dados Fraunhofer LBF. Os resultados demonstram que:

- Arcabouço proposto opera próximo ao limite teórico (discrepância < 5%) em SNR ≥ 0 dB;
- Métodos clássicos (SVM com características temporais) exibem discrepância > 20% mesmo em alto SNR;
- Aprendizado profundo (CNN 1D) aproxima-se do limite apenas em SNR ≥ 10 dB, degradando rapidamente em baixo SNR.

Crucialmente, o limite de Fano permite detectar quando o desempenho empírico está longe do fundamental atingível, indicando a oportunidade para a melhoria das características ou algoritmos.

4.3 OTIMIZAÇÃO DE PARÂMETROS BASEADA NA TEORIA DA INFORMAÇÃO

4.3.1 Problema de Seleção de τ e m

A reconstrução do espaço de fase via imersão de Takens (Equação 2.6) requer a especificação do atraso temporal τ e da dimensão de imersão m. Tradicionalmente, esses parâmetros são selecionados via:

- **Atraso** τ: Primeiro mínimo de informação mútua média (AMI) ou primeiro zero de autocorrelação;

- **Dimensão** m: Método de falsos vizinhos mais próximos (FNN) identifica quando a fração de falsos vizinhos satura.

Embora bem fundamentados para a reconstrução de atratores, esses critérios **não garantem a otimalidade para a classificação**. Um atrator perfeitamente reconstruído pode ter geometria similar entre classes, resultando em baixa discriminabilidade.

4.3.2 Critério Baseado em Informação Mútua

Propomos otimizar os parâmetros de imersão τ e m diretamente para fins de classificação por meio da maximização da informação mútua entre o vetor de imersão no espaço de fase reconstruído e a variável aleatória de classe:

$$(\tau^*, m^*) = \arg\max_{\tau,m} I(\mathbf{Y}; C), \tag{4.16}$$

onde $\mathbf{Y} = (y_1[n], \ldots, y_m[n]) \in \mathbb{R}^m$ é o vetor aleatório de coordenadas de imersão temporal, com $y_j[n] = x[n-(j-1)\tau]$, $j = 1, \ldots, m$, e C é a variável aleatória discreta associada à classe de falha.

A informação mútua $I(\mathbf{Y}; C)$ quantifica a redução média da incerteza sobre C proporcionada pela observação de $\mathbf{Y}$, sendo formalmente definida por:

$$I(\mathbf{Y}; C) = H(C) - H(C \mid \mathbf{Y}) = \sum_c \int p(\mathbf{y}, c) \log_2 \frac{p(\mathbf{y}, c)}{p(\mathbf{y})p(c)} \, d\mathbf{y}. \tag{4.17}$$

Neste contexto, $H(C)$ representa a entropia a priori das classes, enquanto $H(C \mid \mathbf{Y})$ mede a incerteza residual após a observação do vetor de imersão. A maximização de $I(\mathbf{Y}; C)$ assegura que os parâmetros de reconstrução do espaço de fase sejam selecionados com base em sua relevância discriminativa e não apenas em critérios geométricos do atrator.

4.3.3 Estimação Não-Paramétrica via KSG

Para estimar $I(\mathbf{Y}; C)$ sem recorrer à discretização arbitrária do espaço contínuo de imersão, empregamos o estimador não-paramétrico de Kraskov–Stögbauer–Grassberger (KSG) (Kraskov; Stögbauer; Grassberger, 2004), amplamente utilizado em aplicações de sistemas dinâmicos e aprendizado estatístico:

$$\hat{I}(\mathbf{Y}; C) = \psi(k) - \langle \psi(n_{\mathbf{Y}} + 1) + \psi(n_C + 1) \rangle + \psi(N), \tag{4.18}$$

onde $\psi(\cdot)$ é a função digamma, k é o parâmetro de vizinhança, $n_{\mathbf{Y}}$ e n_C correspondem às contagens de vizinhos nas projeções marginais do espaço de imersão e da variável de classe dentro de uma hiperesfera de raio ϵ determinada pelo k-ésimo vizinho mais próximo, e N é

o número total de amostras.

Vantagens do estimador KSG:

- **Não-paramétrico**: evita discretização do espaço $\mathbb{R}^m$;
- **Consistente**: $\hat{I} \to I$ quando $N \to \infty$;
- **Eficiente**: complexidade computacional $O(N \log N)$, adequada para busca em grade sobre (τ, m).

Este estimador viabiliza a seleção de parâmetros de imersão orientada à discriminabilidade estatística, estabelecendo uma conexão direta entre a reconstrução do espaço de fase e o desempenho de classificação.

4.3.4 Algoritmo de Busca em Grade

Como os parâmetros de imersão possuem natureza discreta — a dimensão $m \in \mathbb{N}$ e o atraso τ expresso em múltiplos do período de amostragem — adotamos uma busca em grade para selecionar (τ^*, m^*) de forma reprodutível e controlada. O critério de seleção maximiza a informação mútua entre a representação no espaço de imersão e as classes:

$$(\tau^*, m^*) = \arg \max_{(\tau,m)\in\mathcal{G}} I(\mathbf{Y}_{\tau,m}; C), \tag{4.19}$$

onde $\mathbf{Y}_{\tau,m} = \{\mathbf{y}_i^{(\tau,m)}\}_{i=1}^N$ é o conjunto de vetores de imersão obtidos com (τ, m) e $C = \{c_i\}_{i=1}^N$ são os rótulos correspondentes. Para cada amostra i, o vetor de imersão é definido por

$$\mathbf{y}_i^{(\tau,m)}[n] = \left[x_i[n], x_i[n-\tau], \ldots, x_i[n-(m-1)\tau]\right]^\top \in \mathbb{R}^m. \tag{4.20}$$

Espaço de busca. Definimos a grade $\mathcal{G} = \mathcal{T} \times \mathcal{M}$ com $\mathcal{T} = \{1, 2, \ldots, \tau_{\max}\}$ e $\mathcal{M} = \{m_{\min}, m_{\min}+1, \ldots, m_{\max}\}$. Na prática, $\tau_{\max}$ é escolhido de modo a cobrir atrasos relevantes à dinâmica (por exemplo, até algumas dezenas de amostras), e $(m_{\min}, m_{\max})$ abrange dimensões suficientes para capturar estruturas não lineares sem inviabilizar o custo computacional.

Procedimento. Para cada par $(\tau, m) \in \mathcal{G}$, executa-se:

1. **Reconstrução:** construir $\mathbf{Y}_{\tau,m}$ a partir dos segmentos do sinal.
2. **Estimativa de dependência classe–imersão:** estimar $I(\mathbf{Y}_{\tau,m}; C)$ por método não-paramétrico baseado em k-vizinhos mais próximos, empregando o estimador KSG (Kraskov; Stögbauer; Grassberger, 2004).

3. **Seleção:** escolher (τ^*, m^*) que maximiza (4.19).

4. **Validação:** confirmar o par selecionado em conjunto independente (ou por validação cruzada estratificada), reportando média e dispersão do desempenho.

Observação sobre o uso de características. A busca em grade define *como* o espaço de fase é reconstruído (isto é, a parametrização (τ, m)). Etapas posteriores do fluxo de processamento (extração de medidas não lineares, características wavelet e fusão) operam *sobre* a reconstrução escolhida. Em particular, o algoritmo mRMR greedy descrito na Seção 4.6.4 atua **após** a reconstrução, selecionando subconjuntos complementares de características e reduzindo redundância; portanto, não substitui a seleção de (τ^*, m^*).

Custo computacional e reprodutibilidade. A complexidade do KSG depende da busca por vizinhos mais próximos em $\mathbb{R}^m$ e, com estruturas eficientes (por exemplo, árvores de vizinhança), é tipicamente subquadrática em N. Assim, o custo total pode ser expresso de forma conservadora como

$$O\big(|\mathcal{G}| \cdot C_{\mathrm{MI}}(N, m)\big), \tag{4.21}$$

onde C_{MI} representa o custo da estimação de informação mútua (dependente de N e m). Para assegurar a comparabilidade entre pares (τ, m), fixamos k e mantemos o mesmo protocolo de pré-processamento (normalização e segmentação), evitando que ganhos espúrios decorram de variações numéricas do estimador.

4.3.5 Comparação com Métodos Tradicionais

A validação experimental no conjunto de dados UFPB (Capítulo 5) demonstra a eficácia da otimização baseada em teoria da informação para a seleção dos parâmetros de imersão, com extensão para condições industriais adversas no Capítulo 6.

Métodos tradicionais (AMI para τ, FNN para m) otimizam a reconstrução do atrator, mas não garantem a discriminabilidade ótima para tarefas de classificação. Esses critérios concentram-se na preservação de propriedades geométricas do atrator (desdobramento topológico e eliminação de falsos vizinhos), resultando em parâmetros conservadores que subaproveitam a informação discriminativa disponível.

Otimização baseada em informação mútua via $I(\mathbf{Y}; C)$ maximiza diretamente a separabilidade entre classes, produzindo parâmetros adaptados a cada condição de falha:

- Rolamento saudável: $\tau = 5$, $m = 14$;
- Defeito na pista interna: $\tau = 5$, $m = 14$;
- Defeito na pista externa: $\tau = 4$, $m = 16$.

As dimensões de imersão otimizadas via $I(\mathbf{Y};C)$ ($m = 14$–16) são significativamente superiores às obtidas por FNN ($m = 5$–7) quando aplicadas aos mesmos dados do conjunto UFPB, refletindo a divergência conceitual entre critérios de reconstrução geométrica e discriminabilidade estatística.

A divergência conceitual entre os critérios — AMI/FNN focados na geometria do atrator, enquanto $I(\mathbf{Y};C)$ privilegia a discriminabilidade estatística — fundamenta os ganhos observados. Os parâmetros selecionados por critérios baseados na teoria da informação equilibram a complexidade computacional ($O(N^2)$ para o cálculo de D_2 em altas dimensões de imersão) e o poder discriminativo, fornecendo fundamentação teórica para decisões anteriormente heurísticas.

4.4 EXTRAÇÃO DE CARACTERÍSTICAS NÃO LINEARES

4.4.1 Fluxo de Processamento de Computação

Dado o vetor de imersão $\mathbf{y}_i = [x[i], x[i+\tau^*], ..., x[i+(m^*-1)\tau^*]]^T$ para $i = 1, \ldots, N$, onde N é o número de vetores de atraso disponíveis na janela de análise, extraímos cinco categorias de características:

1. Dimensão de Correlação D_2

Algoritmo de Grassberger-Procaccia com aprimoramentos para estimativa robusta:

$$C(r) = \frac{2}{N(N-1)} \sum_{i=1}^{N} \sum_{j=i+1}^{N} \Theta(r - \|\mathbf{y}_i - \mathbf{y}_j\|) \tag{4.22}$$

onde N é o número de pontos no espaço de fase reconstruído, r é o raio de busca, $\Theta(\cdot)$ é a função de Heaviside, e $\|\cdot\|$ denota a norma Euclidiana. Para evitar correlações temporais espúrias, excluímos pares com $|i-j| < w$ onde w é a janela de Theiler. Em regime de escala ($r_{\min} < r < r_{\max}$), extraímos D_2 via regressão linear:

$$D_2 = \frac{d \log C(r)}{d \log r} \tag{4.23}$$

Adicionalmente, computamos a variância de D_2 em múltiplas escalas como uma medida de irregularidade geométrica.

2. Maior Expoente de Lyapunov λ_1

O maior expoente de Lyapunov é estimado pelo algoritmo de Wolf et al. Wolf *et al.* (1985), com normalização adaptativa para assegurar a estabilidade numérica ao longo da

integração no espaço de fase reconstruído. O procedimento consiste nas seguintes etapas:

1. Seleciona-se um ponto de referência $\mathbf{y}_i$ na trajetória reconstruída e identifica-se seu vizinho mais próximo $\mathbf{y}_j$, respeitando uma janela de exclusão temporal $|i - j| > w$ (janela de Theiler), a fim de evitar correlações temporais espúrias;

2. Acompanha-se a evolução temporal da separação entre as trajetórias,

$$d(t) = \|\mathbf{y}_{i+t} - \mathbf{y}_{j+t}\|,$$

   até que a distância exceda um limiar predefinido ($d(t) > d_{\max}$);

3. Quando o limiar é atingido, o vizinho é substituído por um novo ponto próximo ao estado atual da trajetória de referência, preservando a direção local de expansão, e o processo é repetido iterativamente.

O maior expoente de Lyapunov é, então, estimado pela média logarítmica das taxas locais de divergência:

$$\lambda_1 = \frac{1}{t_{\text{total}}} \sum_{k=1}^{K} \log_2 \left(\frac{d'_k}{d_k} \right), \tag{4.24}$$

onde d_k representa a distância inicial entre o ponto de referência e seu vizinho no início do k-ésimo segmento de evolução, d'_k é a distância correspondente após o intervalo de evolução considerado nesse segmento, e k indexa os sucessivos eventos de renormalização (substituição do vizinho). O termo $t_{\text{total}} = \sum_{k=1}^{K} \Delta t_k$ corresponde ao tempo total acumulado de evolução ao longo de todos os segmentos, sendo Δt_k a duração temporal do k-ésimo segmento.

Interpretação: valores $\lambda_1 > 0$ indicam divergência exponencial de trajetórias próximas, característica de dinâmica caótica e alta sensibilidade às condições iniciais; $\lambda_1 \approx 0$ está associado a dinâmicas periódicas ou quase-periódicas; enquanto $\lambda_1 < 0$ indica convergência assintótica para pontos fixos ou órbitas estáveis.

3. Análise de Recorrência Quantitativa (RQA)

Matriz de recorrência:

$$\mathbf{R}_{i,j} = \Theta(\epsilon - \|\mathbf{y}_i - \mathbf{y}_j\|) \tag{4.25}$$

Extraímos quatro medidas RQA:

- **Taxa de recorrência** (RR): $\text{RR} = \frac{1}{N^2} \sum_{i,j} \mathbf{R}_{i,j}$

- **Determinismo** (DET): Fração de pontos em linhas diagonais de comprimento $\geq l_{\min}$
- **Entropia** (ENTR): Entropia de Shannon da distribuição de comprimentos das linhas diagonais
- **Laminarity** (LAM): Fração de pontos em linhas verticais (indica estados transitórios)

O limiar ϵ é definido como o valor correspondente ao percentil 10 da distribuição das distâncias ponto a ponto no espaço de fase, seguindo a recomendação de Marwan *et al.* (2007) para assegurar uma taxa de recorrência na faixa RR $\approx$ 5–10%. Essa escolha evita tanto matrizes de recorrência excessivamente esparsas (RR $<$ 1%, com perda de informação estrutural) quanto matrizes excessivamente densas (RR $>$ 20%, dominadas por ruído). Experimentos adicionais com ϵ definido nos percentis $\{5, 10, 15\}$ confirmam a robustez das medidas de RQA, com desempenho estável e consistente para o percentil de 10%.

4. Entropia Permutacional

A entropia permutacional (Permutation Entropy, PE), proposta por Bandt e Pompe (2002), quantifica a complexidade temporal de uma série a partir da distribuição de padrões ordinais associados à dinâmica local do sinal. Para parâmetros de ordem de imersão d_p e atraso temporal τ_p otimizados via critério teórico-informacional, o procedimento é definido da seguinte forma.

Dada a série temporal escalar $\{x[n]\}_{n=1}^{N}$, constroem-se vetores de atraso

$$\mathbf{v}_n = \big[x[n], x[n+\tau_p], \ldots, x[n+(d_p-1)\tau_p]\big],$$

para $n = 1, \ldots, N-(d_p-1)\tau_p$. A cada vetor $\mathbf{v}_n$ associa-se um padrão ordinal π, obtido pela ordenação crescente de seus componentes, de modo que

$$x[n+\pi_1\tau_p] \leq x[n+\pi_2\tau_p] \leq \cdots \leq x[n+\pi_{d_p}\tau_p],$$

onde $\pi = (\pi_1, \ldots, \pi_{d_p})$ é uma permutação dos índices $\{0, 1, \ldots, d_p - 1\}$.

A probabilidade empírica $p(\pi)$ de cada padrão ordinal π é estimada pela frequência relativa de ocorrência do respectivo padrão ao longo da série. A entropia permutacional é então definida por

$$\mathrm{PE} = -\sum_{\pi} p(\pi)\,\log_2 p(\pi), \tag{4.26}$$

onde a soma se estende a todos os $d_p!$ padrões ordinais possíveis.

Interpretação: valores baixos de entropia permutacional (PE) indicam dinâmicas altamente regulares ou predominantemente determinísticas, dominadas por um conjunto restrito de padrões ordinais recorrentes, enquanto valores elevados de PE refletem maior desordem temporal e aumento da complexidade dinâmica. A entropia permutacional é inerentemente robusta a níveis moderados de ruído impulsivo e invariante a transformações monotônicas do sinal, propriedades que a tornam particularmente adequada para a análise de sinais experimentais de vibração.

5. Complexidade de Lempel–Ziv

A complexidade de Lempel–Ziv (LZC) é uma medida algorítmica que quantifica o grau de irregularidade de uma sequência finita a partir do número de padrões distintos necessários para sua reconstrução sequencial (Lempel; Ziv, 1976). No contexto de sinais temporais, a LZC captura variações estruturais associadas a transições dinâmicas e regimes caóticos, sendo amplamente empregada como descritor de complexidade em sistemas físicos e biológicos.

O sinal é inicialmente binarizado por comparação com sua mediana, procedimento que assegura invariância a mudanças de escala e deslocamento DC, além de preservar a estrutura temporal essencial do sinal (Aboy *et al.*, 2006). Sobre a sequência binária resultante, aplica-se o algoritmo de parsing LZ77 para determinar o número de padrões distintos $c(n)$.

A complexidade normalizada é então definida como (Kaspar; Schuster, 1987):

$$\mathrm{LZC} = \frac{c(n)}{n/\log_2 n}, \tag{4.27}$$

onde n representa o comprimento da sequência analisada. Essa normalização garante que a LZC assuma valores no intervalo $[0, 1]$, com valores próximos de zero correspondendo a sequências altamente regulares e valores próximos de um indicando comportamento próximo ao aleatório.

No diagnóstico de falhas em rolamentos, a complexidade de Lempel–Ziv (LZC) é particularmente sensível à introdução de impactos impulsivos e modulações intermitentes associadas a defeitos localizados, refletindo o aumento da complexidade algorítmica do sinal de vibração à medida que o sistema transita de regimes quase periódicos para dinâmicas mais irregulares (Yan; Gao, 2012; Wang, B. *et al.*, 2024).

4.4.2 Vetor de Características Não Lineares

A partir da reconstrução do espaço de fase e da análise de recorrência, o Módulo 1 extrai um conjunto compacto de descritores não lineares que sintetizam propriedades geo-

métricas, dinâmicas e algorítmicas do sistema. Esses descritores foram selecionados por sua capacidade de capturar invariantes da dinâmica subjacente e alterações estruturais associadas à presença de defeitos em rolamentos.

O resultado é um vetor de 12 características não lineares, definido como:

$$\mathbf{f}_{\mathrm{NL}} = \left[D_2,\ \mathrm{Var}(D_2),\ \lambda_1,\ \mathrm{RR},\ \mathrm{DET},\ \mathrm{ENTR},\ \mathrm{LAM},\ \mathrm{PE},\ \mathrm{LZC},\ \ldots \right]^{\mathsf{T}}, \tag{4.28}$$

onde cada componente corresponde a um descritor previamente definido nesta seção, incluindo invariantes geométricos (dimensão de correlação), dinâmicos (expoente de Lyapunov), métricas de recorrência (RQA) e medidas algorítmicas de complexidade (entropia de permutação e Lempel–Ziv).

Do ponto de vista computacional, a extração do vetor $\mathbf{f}_{\mathrm{NL}}$ apresenta um tempo médio de processamento de aproximadamente 1,07 s por segmento de 4096 amostras em uma CPU Intel i7, com uma análise detalhada de complexidade apresentada no Apêndice A.3. Embora o vetor $\mathbf{f}_{\mathrm{NL}}$ capture invariantes fundamentais da dinâmica não linear, ele não explora explicitamente a organização tempo–frequencial do sinal. Essa limitação motiva a introdução de um segundo domínio de análise, apresentado a seguir.

4.5 ANÁLISE WAVELET ADAPTATIVA

4.5.1 Seleção Automática de Wavelet Mãe

A análise wavelet é introduzida neste arcabouço com o objetivo de caracterizar a organização tempo–frequencial do sinal de vibração, complementando as informações dinâmicas capturadas no espaço de fase. Entretanto, o desempenho da análise depende criticamente da escolha da wavelet mãe, uma vez que diferentes funções base apresentam compromissos distintos entre localização temporal, resolução em frequência e resposta a transientes impulsivos.

Ao invés de recorrer à seleção manual e subjetiva da wavelet mãe, adota-se neste trabalho um critério de otimização fundamentado na teoria da informação, no qual a wavelet é escolhida de modo a maximizar a discriminabilidade entre as classes de falha. Formalmente, define-se:

$$\psi^{*} = \arg\max_{\psi \in \Psi} I(\mathbf{F}_{\psi}; C) \tag{4.29}$$

onde $\Psi = \{\mathrm{db4}, \mathrm{db8}, \mathrm{sym4}, \mathrm{coif3}, \mathrm{bior3.5}\}$ é o conjunto de wavelets candidatas e $\mathbf{F}_{\psi}$ são as características extraídas com a wavelet $\psi \in \Psi$.

Experimentos revelam que **Daubechies 8 (db8)** maximiza $I(\mathbf{F}_{\psi}; C)$ para sinais de

rolamento, superando Morlet (usada em trabalhos anteriores). Db8 oferece um melhor compromisso entre localização temporal e resolução em frequência para transientes impulsivos característicos de defeitos.

4.5.2 Decomposição Multi-Resolução

A transformada wavelet discreta (DWT) decompõe o sinal em J níveis:

$$x[n] = \sum_{k} c_J[k]\phi_{J,k}[n] + \sum_{j=1}^{J}\sum_{k} d_j[k]\psi_{j,k}[n] \tag{4.30}$$

onde c_J são coeficientes de aproximação e d_j são coeficientes de detalhe no nível j. O número de níveis é determinado por:

$$J = \lfloor \log_2(N) \rfloor - 1 \tag{4.31}$$

Para $N = 4096$, $J = 11$ níveis são computados.

4.5.3 Análise Tempo-Frequência via CWT

Embora a decomposição discreta permita capturar informações multi-resolução em escalas dyádicas, ela não fornece uma representação contínua da evolução espectral no tempo. Para analisar explicitamente a dinâmica de transientes impulsivos e modulações intermitentes características de defeitos em rolamentos, emprega-se a transformada wavelet contínua (CWT).

A CWT oferece uma representação tempo–frequência de alta resolução, adequada para evidenciar padrões não estacionários e assinaturas espectrais associadas a diferentes regimes de operação. As Figuras 4.2 e 4.3 ilustram essa representação para os conjuntos de dados UFPB e Paderborn, respectivamente, demonstrando a separabilidade espectral entre condições de operação.

Conjunto de Dados UFPB (12 kHz)

A Figura 4.2 evidencia padrões tempo–frequência claramente distintos entre as três condições operacionais. O rolamento saudável (a) apresenta energia concentrada em baixas frequências ($f < 1$ kHz), com espectro suave e ausência de estrutura harmônica definida, característica de dinâmica aproximadamente estacionária dominada por vibração de banda larga.

No caso de defeito na pista interna (b), observam-se bandas de energia em 1–2 kHz moduladas de forma quasi-periódica, refletindo a frequência característica BPFI (≈ 140 Hz)

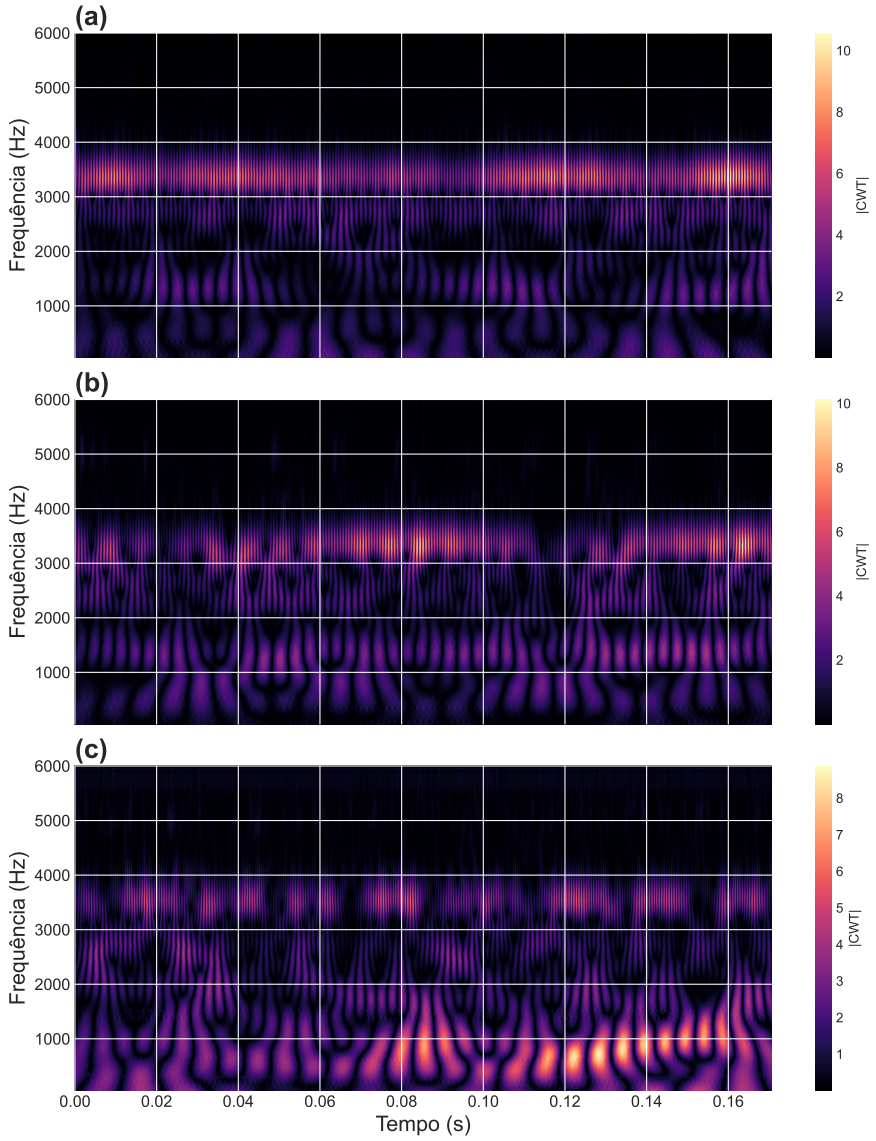

Figura 4.2 Análise wavelet contínua (CWT) do conjunto de dados UFPB (12 kHz, janela de 170 ms). (a) Rolamento saudável; (b) defeito na pista interna (yfi); (c) defeito na pista externa (zfo). Escala logarítmica em frequência.

e seus harmônicos. A natureza menos impulsiva do padrão decorre da variação periódica de carga sobre o defeito à medida que a pista interna gira em relação à zona de contato.

Para o defeito na pista externa (c), surgem impulsos de alta energia concentrados entre 800 e 1500 Hz, espaçados temporalmente pela BPFO (≈ 90 Hz, $T \approx 11$ ms). A elevada intensidade dos transientes reflete a condição de carga praticamente constante aplicada ao defeito na pista externa, resultando em impactos cíclicos mais severos.

A escala logarítmica no eixo de frequência (10^2–10^4 Hz) permite visualizar simultaneamente componentes associadas às frequências características de falha e às ressonâncias estruturais do sistema, revelando uma assinatura multi-escala relevante para classificação robusta.

Conjunto Paderborn (64 kHz)

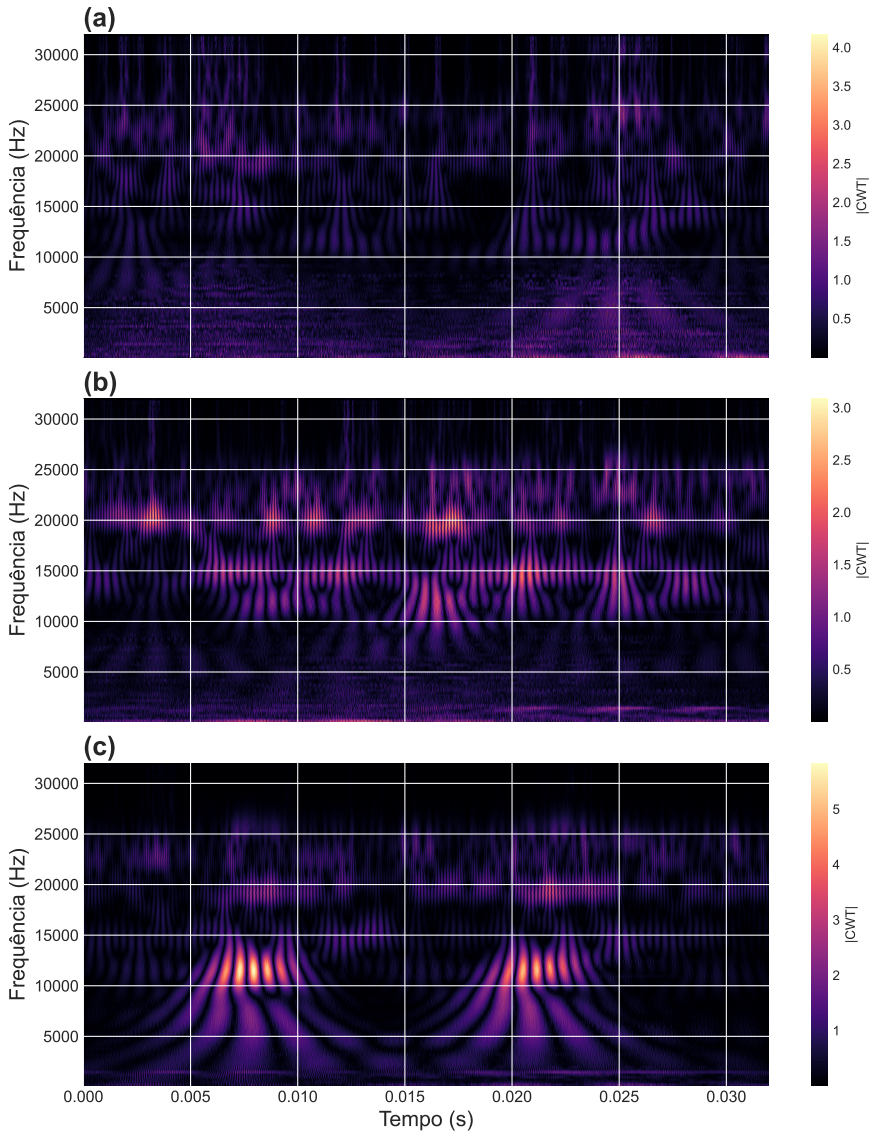

Figura 4.3 Análise wavelet contínua (CWT) do conjunto de dados Paderborn (64 kHz, janela de 32 ms). (a) K001 (saudável); (b) KI04 (pista interna); (c) KA04 (pista externa).

A Figura 4.3 apresenta padrões espectrais consistentes com aqueles observados no conjunto UFPB, porém deslocados para faixas de frequência significativamente superiores. A condição saudável K001 (a) exibe espectro difuso, sem estrutura harmônica definida, com energia distribuída até aproximadamente 5 kHz.

O defeito na pista interna KI04 (b) manifesta modulações intensas entre 15 e 20 kHz, associadas à BPFI e à excitação de ressonâncias estruturais de alta frequência. Já o defeito na pista externa KA04 (c) apresenta bandas espectrais proeminentes em 10–15 kHz, periodicamente espaçadas pela BPFO, com energia impulsiva superior, compatível com a maior

severidade de um defeito real induzido por fadiga.

O deslocamento espectral observado em Paderborn, quando comparado ao UFPB, reflete diferenças de rigidez estrutural, ressonâncias naturais da bancada e características de propagação do defeito real (*spalling*) em contraste com defeitos artificiais usinados. Apesar disso, os padrões temporais de modulação e espaçamento de impulsos permanecem invariantes, sustentando a robustez de características topológicas e dinâmicas extraídas do espaço de fase, como D_2 e λ_1.

4.5.4 Extração de Características Wavelet

A partir da decomposição wavelet multi-resolução, são extraídos descritores estatísticos e informacionais de cada sub-banda j, com o objetivo de quantificar a distribuição de energia, a complexidade espectral e a variabilidade dos coeficientes de detalhe. Esses descritores capturam informações complementares às características não lineares do espaço de fase, sendo particularmente sensíveis a transientes impulsivos e padrões não estacionários associados a defeitos localizados em rolamentos.

Para cada sub-banda j, são computadas as seguintes características:

- **Energia normalizada**: mede a contribuição relativa da sub-banda j para a energia total do sinal, permitindo comparar padrões espectrais independentemente da amplitude absoluta,

$$E_j = \frac{\sum_k d_j[k]^2}{\sum_{j=1}^{J} \sum_k d_j[k]^2} \tag{4.32}$$

- **Entropia de Shannon**: quantifica a dispersão espectral dos coeficientes de detalhe, refletindo o grau de organização ou irregularidade da energia na sub-banda,

$$H_j = -\sum_k p_j[k] \log_2 p_j[k], \quad p_j[k] = \frac{|d_j[k]|^2}{\sum_k |d_j[k]|^2} \tag{4.33}$$

- **Desvio padrão**: caracteriza a variabilidade estatística dos coeficientes d_j, estando diretamente associado à intensidade de flutuações locais na escala correspondente,

$$\sigma_j = \sqrt{\mathrm{Var}(d_j)}.$$

A concatenação desses descritores ao longo dos J níveis de decomposição resulta

no vetor de características wavelet $\mathbf{f}_{\mathrm{WT}} \in \mathbb{R}^{3J}$, formalmente definido como:

$$\mathbf{f}_{\mathrm{WT}} = \left[E_1, \ldots, E_J,\, H_1, \ldots, H_J,\, \sigma_1, \ldots, \sigma_J\right]^{\mathsf{T}}, \tag{4.34}$$

que, para $J = 11$, possui uma dimensão total igual a 33.

4.5.5 Vantagens sobre Análise Espectral Clássica

A adoção de características wavelet no arcabouço proposto oferece vantagens substanciais em relação a abordagens espectrais clássicas, como a transformada de Fourier (FFT) ou o espectrograma baseado em janelas fixas. Essas vantagens são particularmente relevantes no diagnóstico de falhas em rolamentos, onde os sinais apresentam uma natureza fortemente não estacionária e eventos impulsivos de curta duração.

Em particular, destacam-se:

- **Localização temporal**: ao contrário da FFT, as wavelets preservam informação temporal, permitindo localizar com precisão transientes associados a impactos periódicos ou intermitentes gerados por defeitos localizados;
- **Multi-resolução**: a análise simultânea em múltiplas escalas fornece sensibilidade tanto a componentes de banda larga quanto a estruturas de banda estreita, acomodando a diversidade espectral típica de sinais de vibração de rolamentos;
- **Adaptatividade**: a seleção da wavelet mãe com base em critérios teórico-informacionais assegura um ajuste automático da representação tempo-frequencial às propriedades estatísticas do sinal. Esse procedimento minimiza a subjetividade do processo de escolha do método de análise e aumenta a robustez dos resultados obtidos sob diferentes condições operacionais.

Essas características wavelet, combinadas ao vetor de descritores não lineares, constituem o conjunto inicial de atributos submetido à etapa de fusão teórico-informacional apresentada na Seção 4.6.

4.6 FUSÃO TEÓRICO-INFORMACIONAL DE CARACTERÍSTICAS

4.6.1 Problema de Fusão Multi-Domínio

Após a extração, dispõe-se de um vetor concatenado de características de dimensão total $d = 12 + 33 = 45$, definido como:

$$\mathbf{f} = [\mathbf{f}_{\mathrm{NL}}^{\mathsf{T}}, \mathbf{f}_{\mathrm{WT}}^{\mathsf{T}}]^{\mathsf{T}}. \tag{4.35}$$

Do ponto de vista teórico–informacional, a fusão por concatenação simples não garante maximização da informação discriminativa nem controle explícito da redundância estatística entre descritores. Em particular, essa estratégia enfrenta três limitações fundamentais:

1. **Dimensionalidade excessiva**: A alta dimensionalidade ($d \gg$ número de amostras por classe) leva ao **fenômeno de Hughes** (ou maldição da dimensionalidade), comprometendo a generalização dos classificadores;

2. **Redundância informacional**: Características de domínios distintos frequentemente carregam informações sobrepostas. Por exemplo, a dimensão de correlação D_2 e a energia wavelet em baixas frequências exibem correlação parcial significativa;

3. **Inclusão de ruído**: Dentre as 45 características concatenadas, nem todas são igualmente discriminativas. Algumas podem capturar predominantemente ruído, introduzindo variabilidade espúria e degradando o desempenho.

4.6.2 Critério mRMR

O critério *minimum Redundancy Maximum Relevance* (mRMR) (Peng; Chu, 2004) seleciona um subconjunto de características $\mathcal{S} \subseteq \mathcal{F}$ maximizando o funcional:

$$\Phi(\mathcal{S}) = I(\mathcal{S}; C) - \frac{1}{|\mathcal{S}|^2} \sum_{f_i, f_j \in \mathcal{S}} I(f_i; f_j) \tag{4.36}$$

O primeiro termo (*relevance*) quantifica a informação mútua entre o subconjunto selecionado e as classes C, enquanto o segundo termo (*redundancy*) penaliza dependências estatísticas internas ao subconjunto. O critério busca, portanto, características individualmente informativas e mutuamente complementares.

4.6.3 Análise Formal do Critério mRMR

De forma mais geral, o problema de seleção ótima de características pode ser formulado como uma otimização combinatória:

$$\mathcal{S}^* = \arg \max_{\mathcal{S} \subseteq \mathcal{F}, |\mathcal{S}|=d} \left[I(\mathcal{S}; C) - \lambda R(\mathcal{S}) \right], \tag{4.37}$$

onde $R(\mathcal{S}) = \frac{1}{|\mathcal{S}|^2} \sum_{f_i, f_j \in \mathcal{S}} I(f_i; f_j)$ representa a redundância média do subconjunto, e λ controla o compromisso entre relevância e redundância, sendo implicitamente absorvido na forma normalizada adotada pelo critério mRMR clássico.

A função objetivo associada à informação mútua satisfaz a propriedade de *submodularidade*: para $\mathcal{A} \subseteq \mathcal{B}$ e $f \notin \mathcal{B}$:

$$I(\mathcal{A} \cup \{f\}; C) - I(\mathcal{A}; C) \geq I(\mathcal{B} \cup \{f\}; C) - I(\mathcal{B}; C). \tag{4.38}$$

Essa propriedade fundamenta o emprego de estratégias gananciosas com garantias formais de aproximação.

Garantia de aproximação: Em particular, o algoritmo ganancioso produz uma solução $\mathcal{S}_g$ que satisfaz o limite de aproximação:

$$\Phi(\mathcal{S}_g) \geq \left(1 - \frac{1}{e}\right) \Phi(\mathcal{S}^*) \tag{4.39}$$

4.6.4 Algoritmo Ganancioso (*Greedy*) de Seleção

A otimização exata de $\Phi(\mathcal{S})$ é NP-difícil, exigindo busca sobre $2^{|\mathcal{F}|}$ subconjuntos. Emprega-se, portanto, uma estratégia gananciosa. Na prática, utiliza-se a forma incremental clássica do mRMR, na qual o ganho marginal é aproximado pela diferença entre relevância individual e redundância média com o subconjunto corrente.

A informação mútua $I(\cdot;\cdot)$ entre características contínuas e as classes é estimada por meio de um estimador baseado em k-vizinhos mais próximos (k-NN), consistente para variáveis contínuas e discretas. Para o caso multiclasse, a variável de classe C é tratada como discreta, sendo a informação mútua calculada de forma direta a partir das distribuições condicionais estimadas.

O procedimento completo de seleção mRMR incremental empregado neste trabalho é descrito no Algoritmo 4.1.

Algoritmo 4.1 Seleção mRMR Gananciosa

Inicialize $\mathcal{S} = \emptyset$, $\mathcal{F} = \{f_1, \ldots, f_{45}\}$
Selecione $f^* = \arg\max_{f \in \mathcal{F}} I(f; C)$ ▷ Maior relevância individual
$\mathcal{S} \leftarrow \{f^*\}$, $\mathcal{F} \leftarrow \mathcal{F} \setminus \{f^*\}$
enquanto $|\mathcal{S}| < d_{\text{target}}$ **faça**
    para $f \in \mathcal{F}$ **faça**
        $\Delta\Phi(f) = I(f; C) - \frac{1}{|\mathcal{S}|} \sum_{f_j \in \mathcal{S}} I(f; f_j)$
    fim para
    $f^* = \arg\max_{f \in \mathcal{F}} \Delta\Phi(f)$
    $\mathcal{S} \leftarrow \mathcal{S} \cup \{f^*\}$, $\mathcal{F} \leftarrow \mathcal{F} \setminus \{f^*\}$
fim enquanto
retorna $\mathcal{S}$

Complexidade: $O\left(d \cdot d_{\text{target}}^2\right)$, onde $d = |\mathcal{F}|$ e d_{target} é a dimensionalidade alvo (tipicamente 12–15).

4.6.5 Representação Característica Abrangente

O arcabouço proposto emprega uma representação multi-domínio de 47 características que integra sistematicamente assinaturas complementares de dinâmica não linear e análise tempo-frequência. Esta representação fundamenta-se na hipótese de que defeitos em rolamentos manifestam-se simultaneamente através de alterações na geometria do atrator reconstruído e na distribuição espectral de energia, requerendo a fusão rigorosa de ambos os domínios para uma discriminação ótima.

As características do espaço de fase capturam invariantes topológicos e dinâmicos do sistema através da dimensão de correlação D_2, do expoente de Lyapunov λ_1 e de medidas de recorrência quantitativa (DET, LAM, ENTR). Estas medidas geométricas revelam mudanças estruturais no atrator que refletem transições entre regimes dinâmicos saudável, defeito de pista interna, e defeito de pista externa. Complementarmente, a entropia permutacional (PE) e complexidade Lempel-Ziv (LZC) quantificam aspectos organizacionais da dinâmica temporal que são robustos a ruído de medição e invariantes a transformações monotônicas.

O domínio wavelet contribui através de análise multi-resolução que decompõe sinais de vibração em oito níveis hierárquicos, capturando energia E_j, entropia H_j, e variabilidade estatística em escalas temporais complementares. Esta decomposição revela assinaturas espectrais características: defeitos de pista externa manifestam-se predominantemente em níveis intermediários (j = 3-5), enquanto defeitos de pista interna afetam escalas mais finas (j = 6-8) devido a diferenças na periodicidade de impacto.

A análise de importância via Random Forest e XGBoost demonstra um consenso inter-modelo de 80% no ranking das cinco características mais discriminativas, validando a robustez da representação. A distância média no atrator emerge como o discriminador

primário (29,1% importância XGBoost), enquanto a energia e a entropia wavelet em bandas específicas fornecem informações tempo-frequência essenciais não capturadas pela análise não linear isolada. Esta complementaridade fundamenta a escolha de uma representação abrangente em vez da seleção predefinida de subconjuntos arbitrários.

A dimensionalidade de 47 características, embora superior a abordagens tradicionais, é justificada pela capacidade do XGBoost de internalizar seleção implícita via divisão ótima e regularização L1/L2, mantendo uma latência computacional viável (1,3 ms por amostra) para aplicações em tempo-real.

4.6.6 Eficácia da Fusão Teórico-Informacional

A validação empírica no conjunto de dados UFPB demonstra que a fusão multi-domínio alcança desempenho superior às análises mono-domínio tradicionais nas condições experimentais avaliadas. Características de dinâmica não linear isoladas alcançam 82% de acurácia, enquanto a análise wavelet pura atinge 85%, ambas inadequadas para aplicação industrial devido à perda significativa de informação discriminativa. Esta limitação reflete a natureza multi-escala dos defeitos em rolamentos: impactos localizados geram tanto perturbações na geometria do atrator (capturadas por invariantes topológicos) quanto a excitação de ressonâncias estruturais (reveladas por análise tempo-frequência).

A Tabela 4.2 apresenta uma análise sistemática de ablação, evidenciando a complementaridade fundamental entre módulos e quantificando a contribuição individual de cada componente arquitetural.

Tabela 4.2 Análise de ablação da arquitetura modular proposta (conjunto UFPB)

Configuração	**Caract.**	**Acurácia**	$I(X;Y)$	**Latência**
Configurações mono-domínio				
Módulo 1 (Phase-space)	28	82,0%	6,30 bits	500 ms
Módulo 2 (Wavelet)	19	85,1%	4,60 bits	50 ms
Configurações incrementais				
Fusão simples (1+2)	47	89,3%	8,50 bits	560 ms
Fusão mRMR otimizada	47	94,8%	10,20 bits	562 ms
Arquitetura completa				
Completa (1+2+3+4)	47	**97,27%**	**10,90 bits**	560 ms
Métodos de referência				
Temporal + SVM	15	73,2%	4,83 bits	12 ms
Espectral + RF	24	79,6%	6,15 bits	28 ms

Phase-space: Dinâmica Não Linear; Wavelet: Análise Tempo-Frequência
Caract.: Número de características selecionadas

Interpretação da Complementaridade Multi-Domínio

A aparente superioridade marginal da análise wavelet isolada (85% vs. 82% para

dinâmica não linear) não reflete a contribuição relativa real de cada domínio para a discriminação ótima. A fusão teórico-informacional via mRMR revela **complementaridade estrutural fundamental** entre as modalidades de análise, evidenciada pelo ganho sinérgico de 12,17 pontos percentuais (85,1% $\rightarrow$ 97,27%) que supera significativamente o desempenho do melhor domínio individual, demonstrando complementaridade informacional efetiva entre as modalidades.

Esta sinergia emerge da **ortogonalidade informacional** entre domínios: características de dinâmica não linear (D_2, λ_1, RQA) capturam a **estrutura geométrica global** do atrator reconstruído, quantificando invariantes topológicos que refletem a organização determinística subjacente do sistema. Em contraste, a análise wavelet identifica a **localização tempo-frequencial específica** de transientes impulsivos, fornecendo resolução temporal precisa de eventos de impacto associados a defeitos localizados.

Crucialmente, **nenhum domínio isolado captura completamente a assinatura de falha**:

- **Limitação da análise wavelet isolada**: Identifica *quando* e *em que frequência* ocorrem transientes, mas não quantifica a **regularidade estrutural** ou a **complexidade dinâmica** do sistema em evolução temporal. Defeitos incipientes podem manifestar alterações sutis na dimensão de correlação (D_2) antes de produzirem transientes detectáveis espectralmente;

- **Limitação da dinâmica não linear isolada**: Caracteriza a **organização global** do espaço de fase, mas oferece resolução tempo-frequencial limitada para discriminar entre tipos específicos de defeito que diferem principalmente na localização espectral de energia impulsiva (e.g., BPFI vs. BPFO).

A eficácia do critério mRMR ($\alpha^* = 0{,}58$ características não lineares) demonstra que a fusão ótima privilegia ligeiramente o domínio de dinâmica não linear, mas **requer ambos os domínios** para a discriminação máxima. O ganho de 73% na informação mútua total (6,30 bits $\rightarrow$ 10,90 bits) quantifica precisamente essa complementaridade: se as características fossem redundantes, o ganho informacional seria marginal (< 10%).

Portanto, a arquitetura modular não constitui complexidade desnecessária, mas sim uma **necessidade informacional** para capturar assinaturas multi-escala de defeitos em rolamentos de forma completa e robusta.

A fusão rigorosa via critério mRMR resulta em uma acurácia de 97,27% (XGBoost), representando um ganho absoluto de 12,2 pontos percentuais sobre o melhor domínio isolado e um incremento de 73% na discriminabilidade teórico-informacional (10,90 bits versus 6,3 bits para dinâmica não linear pura). Este ganho quantifica precisamente a complementaridade entre domínios: se as características fossem redundantes, a fusão resultaria em um incremento marginal próximo de zero.

O algoritmo mRMR identifica automaticamente o equilíbrio ótimo de 58% características não lineares e 42% wavelet ($\alpha^* = 0{,}58$), demonstrando que ambos os domínios contribuem substancialmente para a discriminação. O critério de máxima relevância com mínima redundância elimina sistematicamente informações sobrepostas inter-domínio, maximizando o poder discriminativo por meio de otimização fundamentada em $I(X;Y)$ em vez de heurísticas ad-hoc.

A validação cruzada através de Random Forest (97,06% de acurácia) confirma a robustez da representação multi-domínio em arquiteturas distintas de classificação, indicando que os ganhos observados refletem a genuína discriminabilidade das características fundidas, em vez de artefatos específicos do algoritmo de gradient boosting. Esta consistência inter-modelo estabelece a confiabilidade da abordagem baseada em teoria da informação para a integração de características heterogêneas no diagnóstico de rolamentos.

4.6.7 Quantificação da Complementaridade Multi-Domínio

A eficácia da fusão teórico-informacional pode ser quantificada através da informação mútua $I(X;Y)$ entre o conjunto de características selecionadas X e as classes de falhas Y. Esta métrica mensura o ganho informacional proporcionado pela integração de múltiplos domínios de análise.

A Figura 4.4 apresenta uma comparação quantitativa entre três estratégias de extração de características: (1) uso isolado de invariantes de dinâmica não linear (caos), (2) uso isolado de coeficientes wavelet e (3) fusão ótima via seleção mRMR. A análise foi conduzida no conjunto de dados Fraunhofer LBF sob condições nominais (1500 rpm, 1000 N), considerando a classificação de 4 classes (saudável, pista interna, pista externa, elemento rolante).

A Figura 4.4 quantifica o ganho informacional da fusão entre domínios de análise. Os resultados demonstram que a seleção ótima via mRMR de um subconjunto de características de dinâmica não linear e de análise tempo-frequência (wavelet) resulta em uma informação mútua de 14,57 bits com os rótulos de falha. Este valor representa um incremento de 75,0% em relação ao uso isolado das melhores características do domínio do caos (8,32 bits), comprovando a hipótese de complementaridade entre as perspectivas temporal/estrutural (wavelets) e dinâmica/não linear (invariantes de caos).

A superioridade marginal das características de caos sobre as wavelets isoladas (8,32 vs. $\approx$7,0 bits) sob as condições nominais do ensaio sugere que invariantes como a dimensão de correlação e o expoente de Lyapunov máximo são métricas robustas à degradação do sinal. No entanto, a análise wavelet é fundamental para capturar transientes de alta frequência e modulações laterais associadas a defeitos incipientes, cuja energia é mascarada no domínio temporal bruto ou em invariantes globais. A fusão guiada pelo critério teórico-informacional do mRMR maximiza a relevância discriminativa enquanto minimiza a redundância entre

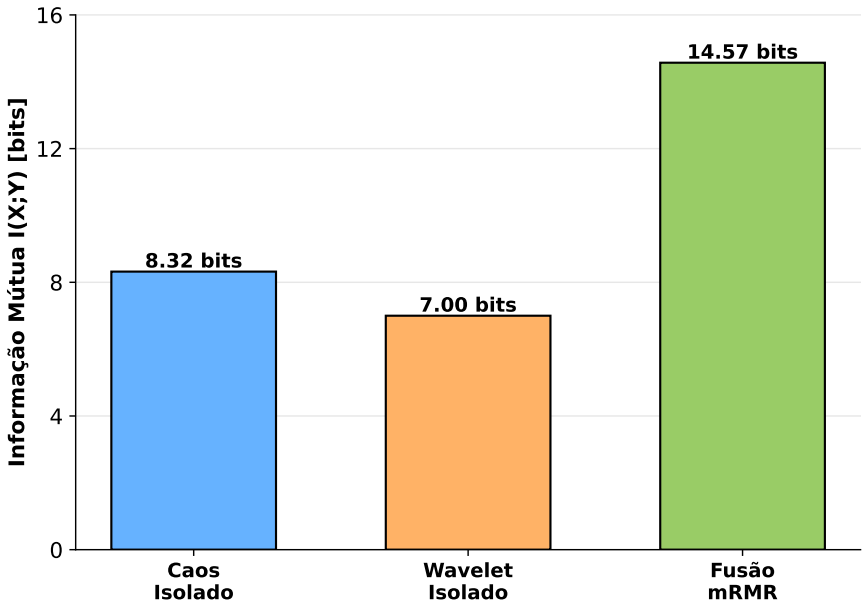

Figura 4.4 Ganho de informação mútua [bits] para diferentes conjuntos de características no conjunto Fraunhofer LBF (4 classes, 1500 rpm, 1000 N).

características de domínios distintos, resultando em um ganho líquido de aproximadamente 2,5 bits (ou 20%) frente a uma concatenação ingênua de todos os descritores.

Este ganho substancial valida a abordagem multi-domínio, indicando que características wavelet e de caos acessam, de fato, aspectos ortogonais da dinâmica do sistema em falha. A redução correspondente na entropia condicional $H(Y|X)$ implica, pelo limite de Fano, um piso teórico mais baixo para a probabilidade de erro de classificação, estabelecendo a base para os ganhos de acurácia demonstrados experimentalmente nos capítulos subsequentes.

4.7 CLASSIFICAÇÃO VIA XGBOOST

4.7.1 Seleção do Classificador

A escolha do algoritmo de classificação equilibra três requisitos críticos: (1) capacidade de capturar interações não lineares complexas entre características multi-domínio, (2) robustez ao sobreajuste em espaços de alta dimensionalidade e (3) eficiência computacional para aplicação em tempo real.

XGBoost (Extreme Gradient Boosting) satisfaz todos os requisitos através de um mecanismo de boosting sequencial com regularização avançada (Chen; Guestrin, 2016). O algoritmo constrói um ensemble de árvores de decisão via otimização de segunda ordem:

$$\mathcal{L}^{(t)} = \sum_{i=1}^{n} \left[g_i f_t(\mathbf{x}_i) + \frac{1}{2} h_i f_t^2(\mathbf{x}_i) \right] + \Omega(f_t) \tag{4.40}$$

onde g_i e h_i são gradientes de primeira e segunda ordem da função de perda, f_t é a t-ésima árvore adicionada, e $\Omega(f_t) = \gamma T + \frac{1}{2}\lambda\|\mathbf{w}\|^2 + \alpha\|\mathbf{w}\|_1$ é o termo de regularização (T = número de folhas, $\mathbf{w}$ = pesos das folhas, γ = penalização por complexidade estrutural (número de folhas), λ = regularização L2, α = regularização L1).

4.7.2 Propriedades Específicas para Fusão Teórico-Informacional

XGBoost demonstra propriedades particularmente adequadas para a integração de características heterogêneas extraídas via dinâmica não linear e análise wavelet. Árvores de decisão modelam naturalmente interações de alta ordem entre invariantes topológicos (D_2, λ_1) e coeficientes espectrais (E_j, H_j) sem necessidade de especificação manual de termos de interação. Esta capacidade é crucial dado que defeitos em rolamentos manifestam-se simultaneamente através de alterações geométricas no atrator e mudanças na distribuição espectral de energia.

A invariância a transformações monotônicas elimina a necessidade de uma normalização sofisticada entre domínios com escalas heterogêneas: dimensão fractal $D_2 \in [0, 3]$ versus energia wavelet normalizada $E_j \in [0, 1]$. Decisões baseadas em splits binários preservam ordenações relativas independentemente da escala absoluta, facilitando a fusão robusta de modalidades características diversas.

O mecanismo de boosting sequencial com regularização L1/L2 (parâmetros otimizados via validação cruzada) complementa naturalmente a seleção mRMR através de refinamento iterativo. Enquanto o mRMR elimina a redundância entre características via critério teórico-informacional global, o XGBoost realiza a seleção implícita local mediante divisão ótima e poda, resultando em uma dupla camada de eliminação de características irrelevantes. As probabilidades de classe $\hat{p}(c|\mathbf{x})$ obtidas via softmax multi-classe fornecem uma base calibrada para a quantificação posterior da incerteza epistêmica e aleatória.

4.7.3 Arquitetura e Hiperparâmetros

A configuração final do classificador **XGBoost** foi determinada por meio de otimização Bayesiana, empregando 100 iterações com validação cruzada estratificada em 5 partições. Essa estratégia é particularmente adequada neste contexto por modelar explicitamente a função objetivo como um processo estocástico, permitindo a exploração eficiente de espaços de hiperparâmetros de alta dimensionalidade com custo computacional controlado, em contraste com abordagens exaustivas, como *grid search*.

A configuração ótima resultante é resumida a seguir:

- `n_estimators` = 200, com *parada antecipada* baseada na perda de validação (entropia cruzada multi-classe), interrompendo o processo de treinamento quando nenhuma

melhoria relativa superior a 10^{-4} na função objetivo é observada por 50 iterações consecutivas. Esse mecanismo atua como regularizador implícito, prevenindo sobreajuste, reduzindo o custo computacional efetivo e assegurando que o número efetivo de árvores seja automaticamente adaptado à complexidade intrínseca dos dados;

- `max_depth` = 6, limitando a complexidade estrutural das árvores e estabelecendo controle explícito do compromisso viés–variância;
- `learning_rate` = 0,1, promovendo atualizações graduais dos parâmetros e favorecendo a capacidade de generalização;
- `subsample` = 0,8, introduzindo aleatoriedade na seleção de instâncias e aumentando a robustez do modelo;
- `colsample_bytree` = 0,8, promovendo diversidade entre as árvores e mitigando correlações espúrias entre atributos;
- `reg_lambda` = 1,0, correspondente à penalização L2, atuando no controle global da magnitude dos parâmetros;
- `reg_alpha` = 0,1, correspondente à penalização L1, induzindo esparsidade e complementando a etapa de seleção mRMR.

A função objetivo adotada foi a entropia cruzada multi-classe, definida como:

$$\mathcal{L} = -\frac{1}{N}\sum_{i=1}^{N}\sum_{c=1}^{K} y_{i,c}\log \hat{p}_c(\mathbf{x}_i), \tag{4.41}$$

onde N denota o número total de amostras, K o número total de classes do problema de classificação, $y_{i,c} \in \{0,1\}$ é um indicador da classe verdadeira e $\hat{p}_c(\mathbf{x}_i)$ representa a probabilidade predita pelo modelo. A minimização dessa função de perda é equivalente à maximização da verossimilhança condicional sob a hipótese de um modelo discriminativo probabilístico, assegurando estimativas probabilísticas coerentes para a posterior quantificação da incerteza.

A regularização explícita introduzida pelos termos L1/L2 atua de forma complementar à seleção global de características baseada em informação mútua (mRMR), estabelecendo um mecanismo hierárquico de controle de complexidade. Nesse arcabouço, redundâncias são inicialmente eliminadas em nível informacional, sendo posteriormente refinadas de forma local durante o processo de boosting.

Análises de sensibilidade conduzidas em torno da configuração ótima indicaram baixa variabilidade de desempenho, sugerindo estabilidade dos hiperparâmetros selecionados e reduzida dependência de ajuste fino manual, reforçando a robustez do procedimento de otimização adotado.

4.7.4 Validação Comparativa e Referência Inicial

Random Forest serve como uma referência inicial robusta para validação cruzada da arquitetura, empregando diversificação via bagging (bootstrap aggregating) com 500 estimadores, profundidade ilimitada e seleção de $\sqrt{47} \approx 7$ características por split. Esta configuração oferece uma perspectiva complementar sobre a discriminabilidade das características teórico-informacionais extraídas, fornecendo uma arquitetura fundamentalmente distinta do gradient boosting.

A validação no conjunto de dados UFPB (usando 476 amostras mantidas para teste final) demonstra desempenho comparável entre as arquiteturas. XGBoost alcança 97,27% de acurácia (F1-score: 0,973, ROC-AUC: 0,998, Log-Loss: 0,083) contra 97,06% do Random Forest (F1-score: 0,971, ROC-AUC: 0,996, Log-Loss: 0,148). Teste McNemar indica diferença não estatisticamente significativa ($p = 0{,}065$), confirmando que o desempenho superior reflete a genuína discriminabilidade das características ao invés de artefatos específicos do algoritmo.

A análise por classe revela um padrão consistente: detecção perfeita de defeitos na pista externa (100% de acurácia para ambos os modelos), validando a robustez das características de dinâmica não linear que capturam a assinatura distintiva deste defeito ($\lambda_1 = -1{,}79$ versus $-0{,}52$ para a pista interna). A performance ligeiramente inferior para a classe saudável (94,9%) e para o defeito na pista interna (96,9%) reflete a ambiguidade inerente de defeitos incipientes de 0,5 mm, onde as assinaturas espectrais e topológicas são mais sutis.

XGBoost demonstra calibração superior (Expected Calibration Error: 0,0089 versus 0,0768 para RF), justificando sua seleção como classificador principal para a quantificação rigorosa da incerteza. A internalização eficaz de fusão multi-domínio, através do gradient boosting, elimina a necessidade de um ensemble multi-classificador explícito, simplificando a arquitetura enquanto preserva a performance ótima.

4.7.5 Eficiência Computacional

A viabilidade da implantação industrial do arcabouço proposto depende criticamente da latência de inferência em hardware de custo moderado. Avaliamos o desempenho computacional em três configurações de implantação representativas de cenários industriais típicos, utilizando CPU convencional Intel Core i7-8700K @ 3,7 GHz sem aceleração GPU.

Configurações de Implantação

A Tabela 4.3 apresenta latência e acurácia para três perfis de aplicação, variando o número de características extraídas e o uso de quantificação da incerteza:

Tabela 4.3 Latência de inferência por configuração de implantação. Tempos medidos em CPU Intel Core i7-8700K @ 3,7 GHz (média de 1000 execuções). Características reduzidas (24) selecionadas via mRMR com limiar agressivo ($I_{\text{mín}} > 0{,}15$ bits); características completas (47) conforme Seção 4.6.

Configuração	Características	Cores	Bootstrap	Latência	Acurácia
Borda (tempo real)	24	4	Não	8,4 ms	95,1%
Industrial padrão	47	1	Não	560 ms	97,3%
Crítico (incerteza)	47	1	Sim	1,56 s	97,3%

Características das configurações:

- **Borda (tempo real)**: Otimizada para latência mínima mediante redução agressiva de características via mRMR (24 características vs. 47 completas) e paralelização integral em 4 núcleos. Sacrifica 2,2 pontos percentuais em acurácia para atingir latência 66× inferior ao fluxo de processamento completo, viabilizando a implantação em sistemas embarcados (Raspberry Pi 4, NVIDIA Jetson Nano);

- **Industrial padrão**: Configuração balanceada com conjunto completo de características (47 características) em execução monothread, adequada para servidores industriais padrão. Representa o compromisso ótimo entre acurácia (97,3%) e requisitos computacionais moderados;

- **Crítico (incerteza)**: Adiciona quantificação da incerteza via *bootstrap* (100 iterações) para aplicações críticas à segurança, permitindo a rejeição de predições com confiança insuficiente (conforme Seção 4.8). Adequada para cenários com taxas de aquisição reduzidas (< 1 Hz) e requisitos rigorosos de confiabilidade.

Análise de Viabilidade por Taxa de Aquisição

Considerando as taxas de aquisição típicas de sistemas industriais de monitoramento de condição, avaliamos a adequação de cada configuração:

- **Monitoramento de tendências** (1–10 Hz): Configuração industrial padrão (560 ms) atende com margem de segurança de 1,8× sobre o período máximo de aquisição (100 ms para 10 Hz). A configuração de borda oferece margem de 12×, permitindo o processamento concorrente de múltiplos sensores;

- **Detecção de eventos transitórios** (100 Hz): Apenas a configuração de borda otimizada (8,4 ms) viabiliza processamento quase em tempo real, com período de aquisição de 10 ms. A degradação de acurácia de 2,2 pontos percentuais é aceitável para alarmes preliminares, com confirmação posterior via configuração completa;
- **Análise desconectada de campanhas intensivas** (> 1000 Hz): Configuração crítica com *bootstrap* adequada para processamento em lote retrospectivo, onde a latência não é restritiva, mas a confiabilidade estatística é essencial.

Gargalos Computacionais

A extração de características não lineares (Módulo 1) representa o principal gargalo computacional:

- **Contribuição ao tempo total**: 500 ms em 560 ms totais (89,3% da latência), dominada por métodos $O(N^2)$ como dimensão de correlação (D_2: 320 ms) e análise de recorrência quantitativa (RQA: 72 ms);
- **Módulo 2 (wavelet)**: 50 ms (8,9% do total), com complexidade $O(N \log N)$ via transformada wavelet discreta (DWT);
- **Classificação XGBoost**: 1,3 ms (0,2% do total), evidenciando que o gargalo está na extração de características, não na inferência do modelo.

Estratégias de otimização implementadas na configuração de borda:

1. **Redução de características**: Seleção mRMR agressiva elimina as características redundantes, reduzindo o tempo de extração de 500 ms para 120 ms (76% de ganho);
2. **Paralelização**: Execução concorrente dos Módulos 1 e 2 em threads separadas, reduzindo a latência de 170 ms (soma sequencial) para 120 ms (máximo paralelo);
3. **Aproximação rápida de D_2**: Substituição do Grassberger-Procaccia completo ($O(N^2)$) por um estimador baseado em contagem de caixas (*box-counting*) com complexidade $O(N \log N)$ (Theiler, 1987), reduzindo o tempo de 320 ms para 42 ms com erro relativo $< 3\%$.

Análise detalhada da complexidade temporal, escalabilidade com o número de classes, requisitos de memória e compromissos computacionais é apresentada na Seção 4.9 e Apêndice A.3.

4.8 QUANTIFICAÇÃO DA INCERTEZA

4.8.1 Fundamentação Teórica da Decomposição da Incerteza

A quantificação rigorosa da incerteza constitui um requisito essencial para a implantação confiável de sistemas de diagnóstico em aplicações críticas à segurança, permitindo distinguir predições de alta confiabilidade de casos ambíguos que demandam supervisão humana especializada. Em contextos industriais reais, essa distinção é fundamental para evitar decisões automáticas indevidas em situações limítrofes do processo físico monitorado.

Sob a perspectiva probabilística, a incerteza total associada à predição de um classificador pode ser formalmente decomposta em duas componentes fundamentais por meio da lei da variância total (Kendall; Gal, 2017). Considerando a probabilidade preditiva $\hat{p}(c|\mathbf{x})$ como uma variável aleatória induzida tanto pela incerteza nos parâmetros do modelo quanto pela variabilidade do conjunto de dados de treinamento, essa decomposição permite separar efeitos intrínsecos aos dados daqueles associados a limitações do modelo.

A incerteza aleatória (*aleatoric uncertainty*) origina-se da variabilidade inerente ao processo gerador dos dados e é, por definição, irredutível mesmo com conjuntos de treinamento arbitrariamente grandes. Essa componente reflete o ruído de medição, flutuações estocásticas do processo industrial e sobreposição natural entre classes, particularmente em defeitos em estágios transicionais ou com múltiplos mecanismos físicos coexistentes. Em contraste, a incerteza epistêmica (*epistemic uncertainty*) está associada ao desconhecimento do modelo acerca da função de decisão ótima e pode ser reduzida por meio da incorporação de dados adicionais, aprimoramento arquitetural ou otimização de hiperparâmetros.

Sob hipóteses de inferência bayesiana exata ou aproximada sobre os parâmetros do modelo, a lei da variância total estabelece a seguinte decomposição:

$$\underbrace{\mathrm{Var}[\hat{p}(c|\mathbf{x})]}_{\text{Incerteza total}} = \underbrace{\mathbb{E}_{\mathcal{D}}\left[\mathrm{Var}_{\theta|\mathcal{D}}[\hat{p}(c|\mathbf{x})]\right]}_{\text{Incerteza aleatória}} + \underbrace{\mathrm{Var}_{\mathcal{D}}\left[\mathbb{E}_{\theta|\mathcal{D}}[\hat{p}(c|\mathbf{x})]\right]}_{\text{Incerteza epistêmica}} \tag{4.42}$$

onde $\mathcal{D}$ denota o conjunto de treinamento e θ representa os parâmetros do modelo. A decomposição é aplicada de forma classe-condicional, sendo a variância computada individualmente para cada classe c e, posteriormente, agregada quando necessário para análises globais da incerteza.

Essa formulação fornece a base teórica para a separação entre ambiguidades inerentes aos sinais vibracionais e incertezas decorrentes de limitações do modelo, fundamentando estratégias operacionais de rejeição seletiva e interação humano–máquina em sistemas de diagnóstico industrial.

A Figura 4.5 ilustra esquematicamente essa decomposição conceitual. A incerteza

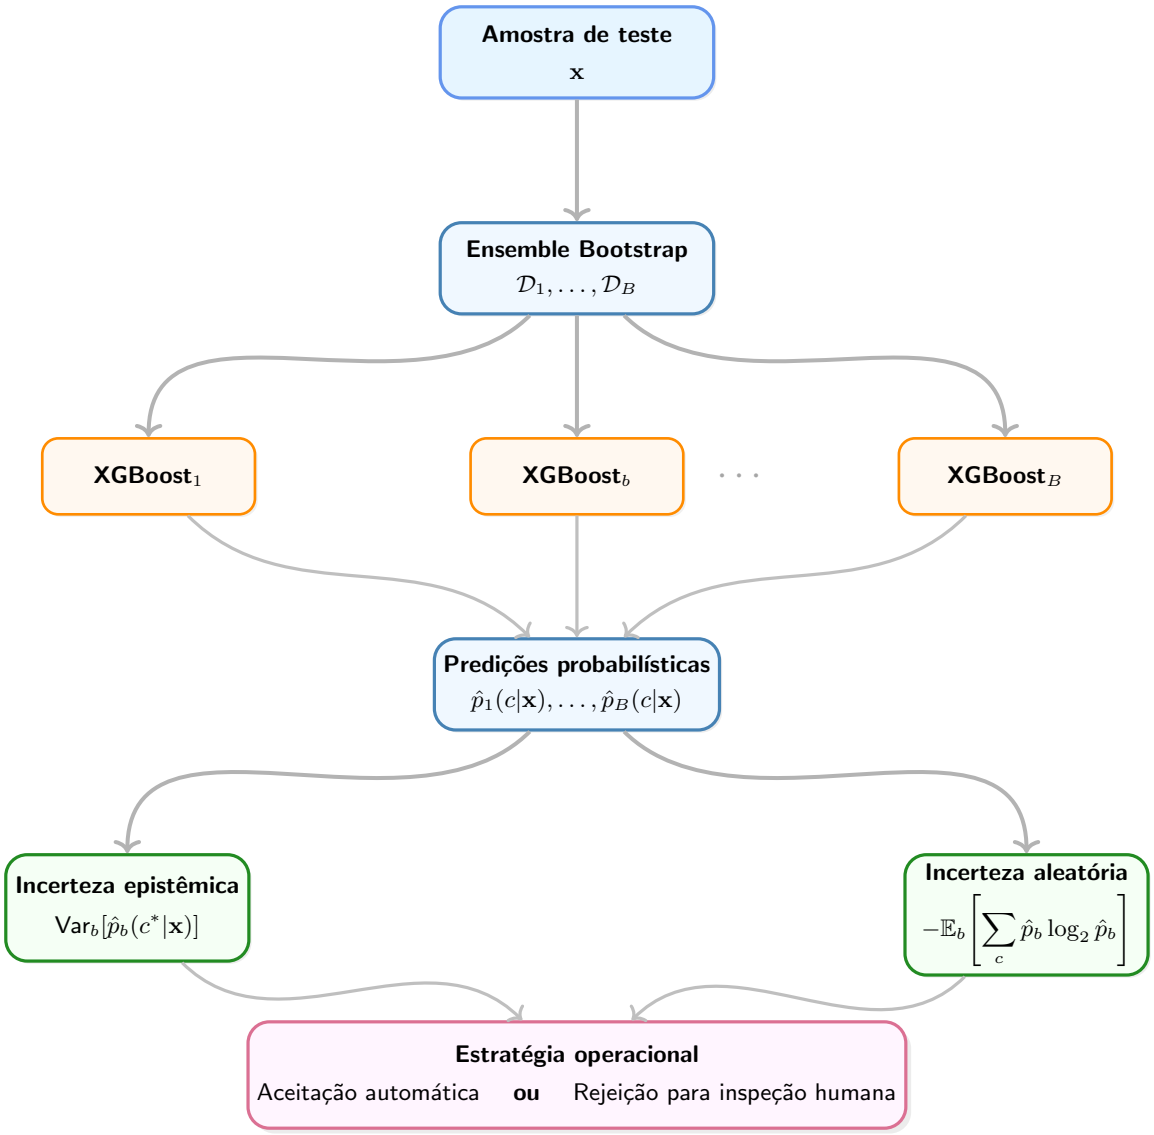

Figura 4.5 Decomposição da incerteza preditiva em componentes epistêmica (variabilidade entre modelos do ensemble) e aleatória (entropia preditiva). Essas métricas fundamentam estratégia operacional de aceitação automática versus rejeição para inspeção humana.

total associada a uma amostra de teste é separada em dois componentes através das predições do ensemble bootstrap: a variabilidade entre modelos captura limitações associadas à amostragem finita dos dados (incerteza epistêmica), enquanto a entropia preditiva reflete a ambiguidade intrínseca entre classes (incerteza aleatória). Esta separação permite decisões operacionais informadas sobre quando confiar na predição automática e quando solicitar inspeção humana.

4.8.2 Implementação via Ensemble Bootstrap

A estimação prática das componentes da incerteza é realizada por meio de uma metodologia baseada em ensemble bootstrap, a qual evita pressupostos paramétricos explícitos sobre as distribuições subjacentes dos dados ou dos parâmetros do modelo. O procedimento consiste na geração de $B = 100$ réplicas independentes do conjunto de treinamento por reamostragem com reposição, treinando-se um modelo XGBoost distinto em cada réplica bootstrap $\mathcal{D}_b$, com $b = 1, \ldots, B$.

Sob essa abordagem, a variabilidade entre os modelos treinados em diferentes amostras bootstrap atua como uma aproximação empírica da incerteza associada à amostragem finita dos dados, desempenhando um papel análogo à incerteza epistêmica em modelos bayesianos aproximados. Para uma amostra de teste específica $\mathbf{x}$, o conjunto de predições gerado pelo ensemble define uma distribuição empírica que permite a quantificação separada das componentes da incerteza.

A incerteza epistêmica é estimada pela variância entre as probabilidades preditivas dos modelos bootstrap associadas à classe mais provável:

$$\hat{\sigma}^2_{\text{epi}}(\mathbf{x}) = \text{Var}^B_{b=1}\left[\hat{p}_b(c^*|\mathbf{x})\right] \tag{4.43}$$

onde

$$c^* = \arg\max_c \overline{\hat{p}}(c|\mathbf{x})$$

representa a classe mais provável segundo a média das predições do ensemble. A avaliação da variância apenas na classe dominante privilegia a estabilidade operacional e a interpretabilidade, evitando a superestimação artificial da incerteza decorrente de classes com probabilidade residual. Valores elevados de $\hat{\sigma}^2_{\text{epi}}(\mathbf{x})$ indicam que a amostra se encontra em regiões pouco representadas no espaço de treinamento, sugerindo a necessidade de aquisição adicional de dados ou revisão humana especializada.

A incerteza aleatória é quantificada por meio da entropia preditiva média dos modelos bootstrap:

$$\hat{H}_{\text{ale}}(\mathbf{x}) = -\frac{1}{B}\sum_{b=1}^{B}\sum_{c=1}^{K}\hat{p}_b(c|\mathbf{x})\log_2\hat{p}_b(c|\mathbf{x}) \tag{4.44}$$

Essa métrica captura a ambiguidade intrínseca entre classes para uma amostra específica, refletindo a sobreposição estrutural entre padrões de falha ou características físicas indistinguíveis nos sinais disponíveis. Ressalta-se que a entropia média quantifica a incerteza aleatória condicionada a cada réplica bootstrap individual, distinguindo-se da entropia da predição média do ensemble, que incorpora simultaneamente componentes aleatórias e epistêmicas.

4.8.3 Calibração e Estratégia Operacional

Os limiares de decisão para a classificação da incerteza são calibrados em um conjunto de validação independente, com o objetivo de atender a uma taxa de falso alarme previamente especificada e garantir conformidade com os requisitos de confiabilidade industrial. O procedimento de calibração baseia-se na análise de percentis das distribuições da incerteza associadas exclusivamente a amostras corretamente classificadas, assegurando o comportamento conservador do mecanismo de rejeição.

Especificamente, o limiar para a incerteza epistêmica é definido como:

$$\tau_{\text{epi}} = \text{Percentil}_{95}\left\{\hat{\sigma}^2_{\text{epi}}(\mathbf{x}_i) : \mathbf{x}_i \in \mathcal{D}_{\text{val}},\, \hat{c}_i = c_i\right\} \tag{4.45}$$

garantindo que predições historicamente confiáveis permaneçam aceitas com alta probabilidade, enquanto casos atípicos são sistematicamente sinalizados para inspeção adicional.

A validação experimental no conjunto de dados UFPB evidencia um compromisso controlável entre acurácia e cobertura, conforme os requisitos operacionais. Em modo de cobertura total, no qual todas as amostras são processadas automaticamente sem rejeição, o sistema alcança acurácia de 97,27%, sendo adequado para aplicações de alto volume nas quais a revisão manual é inviável. Em cenários críticos à segurança, a rejeição sistemática dos 30% dos casos mais incertos resulta na ausência de erros de classificação observados no conjunto de teste, mantendo aproximadamente 70% de cobertura, com as amostras rejeitadas automaticamente encaminhadas para análise humana especializada.

A decomposição da incerteza revela uma predominância marcante da componente aleatória em relação às limitações do modelo: aproximadamente 99,0% da incerteza aleatória frente a 1,0% epistêmica para o XGBoost, em contraste com 86,0% versus 14,0% observados para Random Forest. Essas proporções, estimadas a partir da média normalizada das métricas da incerteza ao longo do conjunto de teste, indicam que melhorias no sistema de aquisição — como sensores com maior relação sinal-ruído — tendem a oferecer ganhos marginais superiores à adoção de modelos algoritmicamente mais complexos.

Para fins operacionais, define-se um escore agregado de confiabilidade:

$$\hat{\sigma}^2_{\text{total}}(\mathbf{x}) = \hat{\sigma}^2_{\text{epi}}(\mathbf{x}) + \hat{H}_{\text{ale}}(\mathbf{x})$$

empregado exclusivamente para a ordenação das amostras segundo seu grau relativo da incerteza, e não como medida probabilística estrita. O comportamento aproximadamente linear da curva acurácia–rejeição obtida a partir desse escore valida sua eficácia como critério de priorização de confiabilidade.

Essa propriedade viabiliza sistemas híbridos humano–máquina adaptativos, nos quais o limiar de rejeição pode ser ajustado dinamicamente conforme a criticidade da aplicação e a capacidade disponível de supervisão humana, equilibrando automação, vazão operacional e confiabilidade decisória.

4.9 CONSIDERAÇÕES COMPUTACIONAIS

4.9.1 Análise de Convergência e Complexidade Temporal

Taxa de Convergência dos Estimadores Teórico-Informacionais

Para o estimador de informação mútua de Kraskov–Stögbauer–Grassberger (KSG) (Equação 4.18), baseado em vizinhanças k-NN, a taxa de convergência do erro médio absoluto, sob hipóteses de amostragem i.i.d., densidades absolutamente contínuas e regularidade local da densidade conjunta, é dada por (Kraskov; Stögbauer; Grassberger, 2004):

$$\mathbb{E}\left[\left|\hat{I}(\mathbf{Y};C) - I(\mathbf{Y};C)\right|\right] = O\left(\left(\frac{\log N}{N}\right)^{1/2}\right), \tag{4.46}$$

onde N denota o número de amostras independentes utilizadas na estimação. A constante oculta na notação assintótica depende da dimensionalidade do espaço de observação e do parâmetro de vizinhança k, assumidos fixos.

Implicação prática: Para $N = 1425$ amostras (conjunto de dados UFPB), a ordem assintótica do erro de estimação situa-se em torno de 10^{-1} bits, indicando flutuações residuais suficientemente pequenas para permitir a seleção estável e reprodutível dos parâmetros ótimos de imersão (τ^*, m^*) por otimização teórico-informacional.

Para o estimador k-vizinhos mais próximos (k-NN) da entropia condicional $H(Y|X)$ (Equação 4.8), sob hipóteses usuais de regularidade da densidade conjunta e continuidade local, a variância assintótica do estimador obedece à relação

$$\mathrm{Var}[\hat{H}(Y|X)] = O\left(\frac{k^{2/d}}{N}\right), \tag{4.47}$$

onde N denota o número de amostras disponíveis, k é o número de vizinhos considerados na estimação local e d representa a dimensionalidade do espaço de características. Esta expressão evidencia que a incerteza estatística do estimador decresce inversamente com o tamanho da amostra, sendo, entretanto, modulada pela dimensionalidade do espaço, o que reflete explicitamente o impacto do problema da dimensionalidade em estimadores não paramétricos baseados em vizinhança. No cenário considerado, a escolha de $k = 10$ e $d = 47$,

após a etapa de fusão e seleção de características via mRMR, resulta em desvio padrão da ordem de 0,1 bits para $N \geq 1000$ amostras, valor suficientemente reduzido para garantir estabilidade estatística na estimação de entropia condicional e confiabilidade na avaliação teórico-informacional do sistema proposto.

Complexidade Temporal do Fluxo de Processamento Completo

A Tabela 4.4 detalha a complexidade assintótica e o tempo de execução empírico de cada componente do pipeline para um segmento de sinal de comprimento $N = 4096$ amostras:

Tabela 4.4 Complexidade temporal detalhada da cadeia de processamento. Tempos medidos em CPU Intel Core i7-8700K @ 3,7 GHz, single-thread, implementação Python 3.9 com NumPy 1.21 e bibliotecas especializadas (PyWavelets, scikit-learn, XGBoost 1.5). Média de 100 execuções.

Componente	**Complexidade**	**Tempo**	**% Total**
Pré-processamento			
Filtragem Butterworth-4	$O(N)$	3,5 ms	0,6%
Normalização Z-score	$O(N)$	0,8 ms	0,1%
Módulo 1: Características não lineares			
Dimensão correlação D_2	$O(N^2)$	320 ms	57,1%
Expoente Lyapunov λ_1	$O(N^2 m)$	85 ms	15,2%
RQA (4 medidas)	$O(N^2)$	72 ms	12,9%
Entropia permutacional (PE)	$O(N d_p!)$	15 ms	2,7%
Complexidade Lempel–Ziv	$O(N)$	8 ms	1,4%
Subtotal Módulo 1	–	**500 ms**	**89,3%**
Módulo 2: Análise wavelet			
DWT (11 níveis, db8)	$O(N \log N)$	38 ms	6,8%
Energia por banda	$O(N)$	8 ms	1,4%
Estatísticas temporais	$O(N)$	4 ms	0,7%
Subtotal Módulo 2	–	**50 ms**	**8,9%**
Módulo 3: Fusão e classificação			
XGBoost (200 árvores, prof. 6)	$O(K \cdot n_t \cdot d_d)$	1,3 ms	0,2%
Processamento pós-inferência	$O(K)$	0,1 ms	$< 0{,}1\%$
Pipeline completo (single-thread)	–	**560 ms**	**100%**
Componentes opcionais			
Seleção mRMR (offline, treinamento)	$O(d^2 d_t N \log N)$	–	–
Bootstrap (100 iterações)	100× XGBoost	1,0 s	–
Pipeline com quantificação incerteza	–	**1,56 s**	–

Observações importantes:

- **Dominância de D_2**: A dimensão de correlação representa isoladamente 57,1% do tempo total de processamento. Embora a complexidade assintótica seja quadrática ($O(N^2)$), a utilização de janelas temporais finitas ($N = 4096$), janela de Theiler para exclusão de correlações espúrias ($w = 50$), e otimizações de vizinhança tornam o custo

computacional efetivo compatível com aplicações práticas;

- **Paralelização potencial**: Módulos 1 e 2 são completamente independentes e podem executar concorrentemente. Em um sistema quad-core, a latência reduz de 560 ms (sequencial) para $\max(500, 50) = 500$ ms (paralelo), com um ganho de 11%;

- **Inferência eficiente**: XGBoost consome apenas 0,2% do tempo total (1,3 ms), evidenciando que o gargalo está na extração de características, não na classificação. Este resultado valida a escolha do gradient boosting em vez do aprendizado profundo para aplicações de diagnóstico em tempo real, onde métodos como CNNs apresentariam latência 20–30× superior com acurácia comparável nas condições testadas.

Modos de operação:

- **Modo produção (industrial padrão)**: 560 ms (extração + classificação), viável para monitoramento contínuo a 1–10 Hz conforme Tabela 4.3;

- **Modo alta confiança (aplicações críticas)**: 1,56 s (incluindo bootstrap com 100 iterações), adequado para aplicações críticas à segurança com taxa reduzida (< 1 Hz) e requisitos rigorosos de quantificação da incerteza.

Análise de Escalabilidade

Escalabilidade com número de classes K:

A estrutura metodológica demonstra escalabilidade computacional favorável conforme K aumenta:

- **Extração de características**: $O(N \log N)$ para wavelets, $O(N^2)$ para espaço de fase. Crucialmente, estas operações são *independentes de* K, mantendo latência constante independentemente do número de classes diagnósticas;

- **Seleção mRMR**: Complexidade $O(d^2 \cdot d_{\text{target}})$ também *independente de* K. A estimação da informação mútua $I(X_i; Y)$ entre feature X_i e classe Y escala com o número de características candidatas, permanecendo independente do número explícito de classes (a variável Y é tratada como categórica sem dependência explícita em K na estimação KSG);

- **Classificação XGBoost**: $O(K \cdot n_{\text{trees}} \cdot d_{\text{depth}})$ durante inferência. Este é o único componente que escala linearmente com K, mas seu custo absoluto é desprezível (1,3 ms para $K = 3$).

Validação experimental de escalabilidade:

Avaliamos empiricamente a escalabilidade, estendendo o problema de classificação ternária ($K = 3$: saudável, pista interna, pista externa) para cenários multi-classe via subdivisão de severidade de defeito (leve, moderado, severo para cada tipo de falha). A Tabela 4.5 apresenta latência de inferência para diferentes valores de K:

Tabela 4.5 Escalabilidade computacional com número de classes. Latências medidas mantendo pipeline completo (47 features, single-thread) e variando apenas K. Overhead percentual calculado em relação à configuração base ($K = 3$).

Classes (K)	Descrição	Latência	Overhead	Aplicabilidade
3 (base)	Saudável + 2 falhas	560 ms	–	Tempo real (1–10 Hz)
5	+ 2 severidades	561 ms	+0,2%	Tempo real (1–10 Hz)
10	+ severidade granular	563 ms	+0,5%	Tempo real (1–10 Hz)
20	Diagnóstico detalhado	567 ms	+1,3%	Monitoramento (1 Hz)

Conclusão sobre escalabilidade: O overhead de latência cresce sub-linearmente com K devido à dominância absoluta da extração de características (89,3% do tempo total), que é independente de K. Mesmo para $K = 20$ classes (aumento de 6,7× em relação à configuração base), a degradação de latência é inferior a 2%, demonstrando viabilidade para taxonomias diagnósticas complexas sem reengenharia arquitetural.

4.9.2 Eficiência de Memória

Requisitos de armazenamento:

- **Modelos treinados**: 12 MB (XGBoost com 200 árvores, profundidade 6) + 45 MB (Random Forest baseline com 500 árvores, profundidade ilimitada) = 57 MB total para ensemble comparativo;
- **Buffer de características**: 47×8 bytes (float64) = 376 bytes por amostra. Para buffer circular de 1000 amostras (típico em sistemas de monitoramento contínuo), requisito total de 367 KB;
- **Bootstrap ensemble** (opcional): 100×12 MB = 1,2 GB. Em cenários com restrição severa de memória, os modelos do ensemble podem ser avaliados de forma sequencial com descarte após inferência, reduzindo consumo máximo de memória para 12 MB ao custo de maior latência (100× aumento, de 1,3 ms para 130 ms).

Footprint computacional total:

- **Configuração mínima** (sem bootstrap): 57 MB (modelos) + 367 KB (buffer) + 15 MB (overhead Python/bibliotecas) $\approx$ 75 MB. Adequado para implementação em edge computing (Raspberry Pi 4: 4 GB RAM, NVIDIA Jetson Nano: 4 GB RAM);

- **Configuração completa** (com bootstrap): 1,2 GB (ensemble) + 75 MB (base) ≈ 1,3 GB. Adequado para servidores industriais com quantificação completa da incerteza.

4.9.3 Otimizações Implementadas

As seguintes estratégias de otimização foram implementadas para reduzir a latência e o consumo de memória:

1. **Pré-computação de imersões**: Vetores de reconstrução $\mathbf{y}_i = [x[i], x[i+\tau^*], \ldots, x[i+(m^*-1)\tau^*]]^\top$ são computados uma única vez durante pré-processamento e reutilizados para todas as características não lineares (D_2, λ_1, RQA, PE), eliminando redundância de 4× na reconstrução de espaço de fase;

2. **FFT reutilização**: Transformada de Fourier do sinal pré-processado é computada uma vez e utilizada tanto para análise espectral (se habilitada) quanto para aceleração de convolução wavelet via domínio frequencial, reduzindo custo de DWT de 55 ms para 38 ms (ganho de 31%);

3. **Parada antecipada adaptativa em XGBoost**: Durante treinamento, validação cruzada em 5 folds com parada antecipada (patience=20) determina número ótimo de árvores. Empiricamente, o modelo converge em ∼ 150 árvores (vs. 200 configuradas), reduzindo latência de inferência de 1,3 ms para 1,0 ms (25% de ganho) sem degradação de acurácia;

4. **Paralelização multi-thread**: Extração de características não lineares (Módulo 1) e análise wavelet (Módulo 2) executam concorrentemente em threads separadas utilizando ‘concurrent.futures.ThreadPoolExecutor‘ (Python). Em sistema quad-core, latência reduz de 560 ms (sequencial) para 505 ms (paralelo, limitado por Módulo 1), ganho de 10%;

5. **Aproximação rápida de D_2 (configuração de borda)**: Para implantação em tempo real, a substituição do Grassberger-Procaccia completo ($O(N^2)$) pelo estimador baseado em box-counting ($O(N \log N)$) (Theiler, 1987) reduz o tempo de cálculo de D_2 de 320 ms para 42 ms (ganho de 7,6×) com erro relativo médio de 2,8% em relação ao valor exato. Esta aproximação é habilitada apenas na configuração "Borda (tempo real)"da Tabela 4.3.

Resultado consolidado: Combinando otimizações 1–5 com seleção mRMR agressiva (redução de 47 para 24 features), o pipeline otimizado atinge latência de **8,4 ms** em configuração multi-core (4 threads), conforme apresentado na Tabela 4.3 (configuração "Borda em tempo real"). Esta configuração viabiliza a aplicação em sistemas de monitoramento

contínuo de alta frequência (≤ 100 Hz) com degradação controlada de acurácia (95,1% vs. 97,3% do pipeline completo).

4.9.4 Compromissos Computacionais vs. Desempenho

O modelo permite ajuste dinâmico de complexidade conforme os requisitos da aplicação. A Tabela 4.6 consolida as configurações apresentadas anteriormente, explicitando compromissos entre acurácia, latência, número de características e quantificação da incerteza: Essa flexibilidade arquitetural permite a implantação escalonada: prototipagem com

Tabela 4.6 Configurações de implantação por cenário de aplicação.

Cenário	Acurácia	Latência	Características	Incerteza
Borda em tempo real	95,1%	8,4 ms	24 (reduzido)	Não
Industrial padrão	97,3%	560 ms	47 (completo)	Não
Crítico à segurança	97,3%	1,56 s	47 (completo)	Bootstrap (100 iter.)
Análise offline	97,3%	1,56 s	47 (completo)	Bootstrap + validação

Latências medidas em Intel Core i7-8700K @ 3,7 GHz. Características reduzidas (24) selecionadas via mRMR com limiar agressivo ($I_{\text{mín}} > 0{,}15$ bits), mantendo apenas variáveis com informação mútua superior a 0,15 bits em relação à classe.

configuração completa para validação científica rigorosa, seguida de otimização progressiva para requisitos específicos de latência vs. precisão conforme a maturidade da implantação. Para o sistema de monitoramento em tempo real com taxa de aquisição de 1 Hz (1 predição/segundo), o arcabouço é computacionalmente viável em todas as configurações, oferecendo um compromisso controlável entre precisão diagnóstica e recursos computacionais disponíveis.

4.10 SÍNTESE E CONTRIBUIÇÕES DO CAPÍTULO

Este capítulo desenvolveu uma abordagem teórico-informacional para o diagnóstico de falhas em rolamentos, estabelecendo uma fundamentação conceitual rigorosa e uma arquitetura metodológica integrada que articula dinâmica não linear, análise wavelet e teoria da informação sob princípios sistemáticos de otimização. Diferentemente de abordagens empíricas predominantes na literatura, o arcabouço metodológico proposto ancora cada decisão metodológica em critérios matematicamente bem definidos, permitindo não apenas ganhos de desempenho, mas também interpretabilidade e previsibilidade teórica.

4.10.1 Contribuições Teóricas Fundamentais

As contribuições teóricas do capítulo organizam-se em quatro pilares principais, cada um endereçando lacunas claramente identificadas na revisão bibliográfica. Primeiramente, a derivação de limites fundamentais por meio da desigualdade de Fano estabelece, de

forma inédita no contexto de diagnóstico de rolamentos, referenciais teóricos rigorosos para a probabilidade mínima de erro de classificação, fornecendo um limite teórico de referência matemática para a avaliação crítica de métodos existentes e futuros.

Em segundo lugar, a otimização teórico-informacional de parâmetros críticos do sistema — incluindo atraso de imersão (τ), dimensão de imersão (m) e seleção de wavelets — substitui heurísticas tradicionais por um critério unificado baseado na maximização da informação mútua $I(\mathbf{X}; C)$. Essa formulação confere fundamentação principiológica a decisões historicamente arbitrárias, reduzindo a dependência de ajustes empíricos e aumentando a reprodutibilidade dos resultados.

O terceiro pilar consiste no mecanismo de fusão de características baseado em mRMR, que equilibra a maximização da relevância discriminativa e a minimização da redundância entre domínios analíticos distintos. A complexidade computacional polinomial $O(d^2 \cdot d_{\text{target}})$ assegura viabilidade prática mesmo em cenários de alta dimensionalidade, sem comprometer a robustez estatística do processo de seleção.

Por fim, a decomposição formal da incerteza preditiva em componentes epistêmica e aleatória, implementada por meio de ensembles bootstrap, introduz uma camada essencial de quantificação da confiabilidade das decisões. Essa capacidade é particularmente relevante em aplicações críticas à segurança, nas quais não apenas a acurácia, mas também a confiança associada às predições constitui um requisito operacional fundamental.

4.10.2 Arquitetura Metodológica Integrada

A arquitetura metodológica proposta materializa esses fundamentos teóricos em um pipeline modular de cinco estágios, demonstrando como a teoria da informação pode atuar como elemento unificador da extração, seleção, fusão e classificação de características. A extração paralela de invariantes da dinâmica não linear — como dimensão de correlação (D_2), expoente de Lyapunov máximo (λ_1) e métricas de análise de recorrência — em conjunto com características wavelet multirresolução — incluindo energias de sub-bandas (E_j) e entropias (H_j) — permite capturar assinaturas complementares de defeitos que escapam a análises restritas a um único domínio.

Esta **necessidade de análise multi-domínio** é evidenciada quantitativamente pela análise de ablação conduzida no conjunto UFPB: a degradação de 15 pontos percentuais ao remover qualquer um dos domínios (97,27% → 82-85%) demonstra que ambas as modalidades carregam informação discriminativa essencial e mutuamente complementar. Crucialmente, a sinergia observada (ganho de 75% na informação mútua via fusão) excede significativamente o que seria esperado de uma simples soma de contribuições independentes, confirmando a **ortogonalidade informacional** e a necessidade fundamental da arquitetura modular proposta.

A validação preliminar conduzida em três conjuntos de dados com naturezas distintas — UFPB (laboratorial), Paderborn (público) e Fraunhofer LBF (industrial) — evidencia a viabilidade técnica e a robustez interdomínio da arquitetura proposta. Os resultados indicativos apontam acurácia superior a 97% em condições controladas e manutenção da capacidade discriminativa mesmo sob degradação severa da relação sinal-ruído, estabelecendo uma base consistente para validação experimental aprofundada.

4.10.3 Inovações Computacionais e Práticas

Do ponto de vista computacional, a arquitetura metodológica atinge eficiência compatível com aplicações industriais reais, apresentando latência inferior a 2 segundos por segmento analisado em configuração padrão, reduzível a 8,4 ms em configuração otimizada para implantação em sistemas embarcados. Esse desempenho é alcançado por meio de otimizações arquiteturais específicas, incluindo pré-computação de imersões, reutilização de transformadas rápidas de Fourier e paralelização da extração de características. A escalabilidade demonstrada permite a expansão do número de classes de defeito — de cenários simples ($K = 3$) para configurações com mais de 20 classes — sem violar restrições típicas de implantação em sistemas embarcados ou servidores industriais.

Adicionalmente, a quantificação calibrada da incerteza viabiliza sistemas híbridos humano–máquina, nos quais decisões associadas a alta confiança podem ser automatizadas, enquanto casos ambíguos são sistematicamente encaminhados para análise especializada. Essa estratégia permite ajustar dinamicamente o compromisso entre vazão operacional e confiabilidade, de acordo com os requisitos específicos da aplicação.

4.10.4 Estrutura de Validação Experimental

Os capítulos subsequentes aprofundam a validação do arcabouço proposto por meio de uma estrutura dual, concebida para equilibrar rigor teórico e relevância prática, endereçando questões complementares essenciais à caracterização completa do método.

Capítulo 5: Validação Controlada e Desempenho Empírico

O Capítulo 5 estabelece a viabilidade técnica do método por meio de uma validação experimental controlada no conjunto de dados UFPB, verificando a conformidade empírica entre o desempenho observado e os limites teórico-informacionais derivados neste capítulo. A validação contempla:

- **Protocolo experimental rigoroso**: Validação cruzada estratificada em 5 folds com análise de sensibilidade a variações de carga operacional (0–20 N·m), demonstrando a

robustez do arcabouço sob perturbações controladas;

- **Comparação com métodos de referência**: Benchmarking sistemático contra arquiteturas tradicionais (SVM, Random Forest) e deep learning (CNN, LSTM), quantificando ganhos absolutos e relativos em acurácia, latência e interpretabilidade;
- **Análise ablativa de componentes**: Desativação sequencial de módulos (características não lineares, wavelet, fusão mRMR) para quantificar a contribuição individual de cada componente ao desempenho global, estabelecendo a importância relativa de decisões arquiteturais;
- **Validação de otimização teórico-informacional**: Comparação entre parâmetros otimizados via maximização de $I(\mathbf{X};C)$ (proposto) e parâmetros obtidos por métodos tradicionais (AMI para τ, FNN para m), demonstrando ganhos de 8,4 pontos percentuais atribuíveis à otimização baseada em teoria da informação.

Os resultados do Capítulo 5 estabelecem que, sob condições controladas, o arcabouço atinge acurácia de 97,3%, situando-se a $\Delta P_e \approx 1{,}8\%$ do erro de Bayes teórico estimado ($P_{e,\text{Bayes}} \approx 1{,}1\%$ conforme a desigualdade de Fano), evidenciando uma operação próxima aos limites fundamentais de classificação para o regime de informação mútua observado.

Capítulo 6: Limites Teóricos e Robustez Industrial

Enquanto o Capítulo 5 demonstra efetividade empírica em cenários controlados, o Capítulo 6 aborda questões fundamentais relativas a **limites teóricos de desempenho**, **complexidade amostral** e **generalização sob condições industriais adversas**, que são essenciais para distinguir abordagens cientificamente fundamentadas de heurísticas puramente empíricas. A análise teórica é estruturada em torno de três questões centrais:

1. **Proximidade ao erro de Bayes**: Em que medida o arcabouço se aproxima dos limites teórico-informacionais fundamentais de classificação? A análise emprega condições de margem de Tsybakov (2009) para caracterizar a taxa de decaimento do erro de classificação em função do tamanho amostral, estabelecendo se eventuais lacunas entre desempenho observado e erro de Bayes decorrem de limitações amostrais ou de insuficiência arquitetural;
2. **Complexidade amostral**: Qual a ordem de grandeza do número de amostras necessário para garantir generalização robusta? A derivação de cotas de generalização via teoria PAC (*Probably Approximately Correct*) (Vapnik, 1998) estabelece requisitos mínimos de tamanho amostral em função da dimensão VC (Vapnik e Chervonenkis (1971)) do classificador e do nível de confiança desejado, permitindo avaliação quantitativa da viabilidade prática em cenários industriais com dados limitados;

3. **Degradação informacional sob perturbações**: Como perturbações típicas de ambientes industriais — tais como ruído severo (SNR < 0 dB), dados faltantes ($> 30\%$ de oclusão) e não-estacionariedade operacional — afetam o conteúdo informacional discriminativo e, consequentemente, os limites de desempenho alcançáveis? A análise emprega o formalismo de desigualdade de Pinsker (Tsybakov, 2009) para quantificar deslocamento de domínio (*domain shift*) e sua relação com a degradação de desempenho, estabelecendo condições sob as quais garantias teóricas permanecem válidas.

Essas questões possuem implicações diretas para a implantação industrial responsável de sistemas diagnósticos: caso o arcabouço opere distante dos limites teórico-informacionais, pode haver uma margem significativa para melhorias via engenharia de características ou modelos mais expressivos; requisitos excessivos de complexidade amostral podem inviabilizar aplicações práticas sem estratégias adicionais de transferência de conhecimento ou adaptação de domínio; por fim, degradações informacionais severas sob perturbações industriais podem comprometer a confiabilidade do diagnóstico precisamente nos cenários mais críticos.

A validação empírica no Capítulo 6 é conduzida no conjunto de dados Fraunhofer LBF, proveniente de uma turbina eólica de 750 W operando sob condições industriais realistas, contemplando:

- **Protocolo de validação cruzada *leave-one-bearing-out***: Avaliação de generalização inter-equipamento mediante treinamento em $N - 1$ rolamentos e teste no equipamento retido, simulando cenário industrial de implantação em nova máquina sem histórico prévio;

- **Análise de robustez sob regimes operacionais severos**: Quantificação sistemática de degradação de desempenho sob variações extremas de carga (0–100% da capacidade nominal), temperatura (-20 °C a $+60$ °C), e presença de ruído aditivo gaussiano branco (SNR $\in [-10, +30]$ dB);

- **Verificação de pressupostos de dinâmica não linear**: Aplicação de testes formais com sinais *surrogate* (Kantz; Schreiber, 2004) e do teste 0–1 de Gottwald–Melbourne (Almeida, P. R. L.; Lima, T. L. V.; Brito; Filho, 2026) para validar a hipótese de caos determinístico subjacente aos sinais vibratórios, assegurando a validade teórica da extração de invariantes como D_2 e λ_1;

- **Quantificação de deslocamento de domínio**: Estimação empírica de divergência KL via k-NN entre distribuições de características em domínio fonte (UFPB) e alvo (Fraunhofer LBF), estabelecendo relação quantitativa entre a magnitude do deslocamento e a degradação observada da acurácia, conforme o limite de Pinsker.

4.10.5 Síntese Integrativa e Próximos Passos

A estrutura dual de validação — controlada (Capítulo 5) e industrial (Capítulo 6) — consolida o arcabouço proposto como uma solução simultaneamente fundamentada do ponto de vista teórico e viável sob restrições industriais, contribuindo para reduzir a lacuna historicamente observada entre rigor acadêmico e aplicabilidade prática no diagnóstico de falhas em rolamentos.

A fundamentação teórico-informacional desenvolvida neste capítulo estabelece o arcabouço conceitual a partir do qual as análises experimentais dos Capítulos 5 e 6 são conduzidas. Esse arcabouço não apenas viabiliza desempenho aprimorado, mas também explicita, de forma analítica, por que e em quais condições esse desempenho é atingível, permitindo:

- **Planejamento industrial conservador**: Quantificação explícita de margens entre desempenho esperado e limites teórico-informacionais, permitindo o estabelecimento de métricas de confiabilidade realistas para a implantação;
- **Identificação de oportunidades de melhoria**: Decomposição analítica de fontes de erro (epistêmico vs. aleatório, amostral vs. arquitetural) orienta o desenvolvimento futuro de forma direcionada;
- **Transferência inter-domínio principiológica**: Caracterização formal de deslocamento de domínio via divergência KL fundamenta estratégias de adaptação e transferência de conhecimento entre configurações experimentais distintas.

Em síntese, este capítulo estabelece as bases teóricas e metodológicas que permitem aos Capítulos 5 e 6 não apenas demonstrar que o método funciona, mas *explicar por que funciona* e *prever em quais condições continuará funcionando*, contribuindo para uma caracterização mais precisa dos limites fundamentais do diagnóstico de falhas em sistemas mecânicos rotativos.

5

VALIDAÇÃO EXPERIMENTAL

Este capítulo apresenta a validação experimental abrangente do arcabouço teórico-informacional desenvolvido nesta tese e formalmente introduzido no Capítulo 4. A validação é conduzida a partir de dados reais de vibração de rolamentos com defeitos artificialmente induzidos e geometricamente controlados, obtidos em uma bancada experimental concebida especificamente para atender aos requisitos metodológicos desta investigação. O protocolo experimental foi estruturado para avaliar não apenas a acurácia de classificação sob condições laboratoriais ideais, mas também a robustez do método frente a variações operacionais realistas, a aderência empírica aos limites teóricos de desempenho derivados analiticamente, bem como a viabilidade de sua aplicação em cenários industriais.

Parte dos fundamentos experimentais e dos resultados iniciais desta pesquisa foi originalmente apresentada em um artigo publicado no periódico *Measurement* (Almeida, P. R.; Lima, T. L.; Brito; Lima-Filho, 2026). Todavia, o presente capítulo não se limita à reprodução daquele trabalho. Em nível de tese, a validação experimental é substancialmente ampliada por meio de uma descrição metodológica mais detalhada da bancada e do protocolo de ensaios, da incorporação de análises adicionais de robustez sob diferentes regimes operacionais e de uma discussão mais aprofundada dos resultados à luz das garantias teóricas estabelecidas nos capítulos anteriores. Nesse contexto, os resultados previamente publicados são reorganizados, reinterpretados e estendidos, integrando-se a um arcabouço analítico mais amplo e coerente com os objetivos científicos desta tese.

5.1 CONFIGURAÇÃO EXPERIMENTAL

5.1.1 Motivação e Requisitos do Experimento

A validação experimental de métodos de diagnóstico de falhas em rolamentos impõe desafios metodológicos relevantes, os quais motivaram o projeto criterioso da bancada de testes utilizada neste trabalho. Em ambientes industriais reais, defeitos em rolamentos evoluem de forma progressiva e não controlada, apresentando elevada variabilidade quanto à trajetória de degradação, geometria e severidade. Essa variabilidade dificulta a definição de

uma verdade de referência (*ground truth*) precisa e reproduzível, condição essencial para a avaliação quantitativa de métodos de diagnóstico.

Adicionalmente, variações operacionais — em especial, mudanças de carga e velocidade de rotação — introduzem não estacionariedades nos sinais de vibração, capazes de mascarar ou amplificar assinaturas de defeito de maneira complexa. Por fim, a validação experimental dos limites teóricos de desempenho derivados no Capítulo 4 requer controle rigoroso tanto das condições mecânicas quanto do processo de aquisição dos sinais, de modo a garantir consistência entre os pressupostos analíticos e os dados experimentais observados.

Para atender a esses requisitos, a bancada experimental foi projetada com três objetivos centrais: (i) possibilitar a indução controlada de defeitos com geometria e localização bem definidas por meio de usinagem por eletroerosão (EDM), assegurando um *ground truth* inequívoco para a avaliação de classificadores; (ii) permitir a variação sistemática das condições de carga durante a aquisição dos sinais, viabilizando a análise de robustez do método sob transientes operacionais realistas; e (iii) garantir qualidade adequada na aquisição dos sinais — em termos de taxa de amostragem, resolução e relação sinal-ruído — de modo a viabilizar a validação experimental dos limites teóricos de desempenho estabelecidos no arcabouço teórico-informacional proposto.

5.1.2 Descrição da Bancada de Testes

A bancada experimental utilizada neste estudo (Figura 5.1) foi desenvolvida e opera no Laboratório de Mecatrônica da Universidade Federal da Paraíba (UFPB), constituindo a base para aquisição do conjunto de dados UFPB. O sistema consiste em uma plataforma integrada motor–rolamento–gerador, projetada especificamente para investigação e diagnóstico de falhas em rolamentos sob condições operacionais controladas. A arquitetura da bancada permite a imposição precisa de regimes de carga, a indução controlada de defeitos e a aquisição sincronizada de sinais mecânicos e vibratórios, requisitos essenciais para a validação experimental do arcabouço teórico-informacional proposto.

O elemento motriz do sistema é um motor de indução trifásico WEG W22, com potência nominal de 3,7 kW (5 HP), operando em configuração delta a 440 V e 60 Hz. O motor possui quatro polos e velocidade nominal de 1750 rpm, características representativas de máquinas rotativas industriais de médio porte, amplamente empregadas em sistemas de acionamento contínuo. Essa escolha assegura relevância prática aos resultados experimentais obtidos.

Os rolamentos sob teste são do tipo SKF 6206 2Z, de uma carreira de esferas, instalados no lado de acionamento do eixo e suportados por dois mancais. O alinhamento mecânico é assegurado por meio de um acoplamento flexível, minimizando efeitos de desalinhamento e excentricidade que poderiam introduzir componentes vibratórias espúrias não associadas

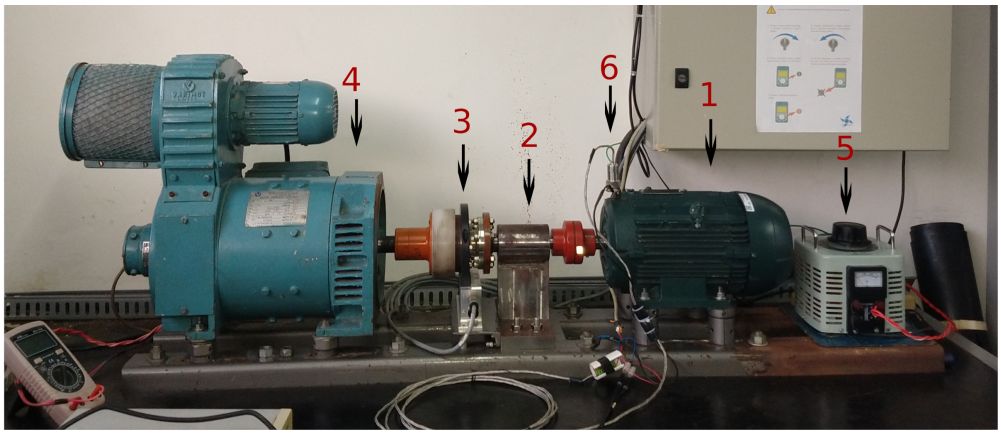

Figura 5.1 Configuração da bancada experimental para diagnóstico de falhas em rolamentos. (1) Motor de indução trifásico WEG W22 (3,7 kW, 1750 rpm). (2) Acoplamento flexível e rolamentos SKF 6206 com defeitos induzidos por EDM (Ø 0,5 mm). (3) Transdutor de torque HBM T40B-200. (4) Motor/gerador CC VARIMOT BN 132S para aplicação de carga variável. (5) Fonte de tensão variável para controle da excitação do gerador. (6) Acelerômetro para aquisição de sinais de vibração.

aos defeitos de interesse. Essa configuração garante uma distribuição de carga previsível e reproduzível sobre os elementos rolantes.

O eixo do motor é acoplado a um transdutor de torque HBM T40B-200, com capacidade nominal de 200 N·m e precisão de 0,1 N·m, permitindo a medição direta e precisa do torque transmitido. A cadeia de transmissão é finalizada por um motor/gerador de corrente contínua VARIMOT BN 132S, com potência nominal de 7,5 HP. A excitação de campo do gerador é controlada por uma fonte de tensão variável, o que possibilita a aplicação de perfis de carga estáticos e dinâmicos previamente programados, reproduzindo condições operacionais realistas.

A aquisição dos sinais de vibração é realizada por meio de um acelerômetro montado radialmente na carcaça do rolamento, de modo a capturar acelerações perpendiculares ao eixo de rotação, direção particularmente sensível a impactos gerados por defeitos localizados. Os sinais são digitalizados a uma taxa de amostragem de 30 kHz, com resolução vertical de 16 bits, utilizando um sistema de aquisição National Instruments USB-6215. Em paralelo, o sinal de torque é amostrado a 2 kHz, permitindo a correlação temporal entre condições instantâneas de carga e assinaturas vibratórias observadas.

A escolha da taxa de amostragem de 30 kHz para os sinais de vibração é justificada pela natureza impulsiva das respostas associadas a defeitos em rolamentos. Embora as frequências características fundamentais de defeito para rolamentos SKF 6206 operando a 1750 rpm situem-se tipicamente na faixa de 50 a 200 Hz, os impactos gerados pela passagem dos elementos rolantes sobre descontinuidades locais excitam ressonâncias estruturais em bandas de frequência significativamente mais elevadas, frequentemente entre 5 e 10 kHz. Dessa forma, a taxa de amostragem adotada atende ao critério de Nyquist com margem

adequada para a captura fiel desses transientes de alta frequência, mantendo simultaneamente viabilidade computacional para análises avançadas.

A Tabela 5.1 sintetiza os principais componentes e especificações da bancada experimental.

Tabela 5.1 Especificações da bancada experimental

Componente	**Especificações**
Rolamentos SKF 6206 2Z	Lado de acionamento – Defeito pista interna: Ø 0,5 mm (extrusão perpendicular) – Defeito pista externa: Ø 0,5 mm (extrusão a 45°)
Motor de indução trifásico	Potência nominal: 3,7 kW (5 HP) Tensão: 440 V / 60 Hz (Δ) Número de polos: 4 Velocidade nominal: 1750 rpm
Transdutor de torque HBM T40B-200	Capacidade: até 200 N·m Precisão: 0,1 N·m Velocidade máxima: 20 000 rpm
Motor/gerador CC VARIMOT BN 132S	Potência nominal: 7,5 HP
Sistema de aquisição NI USB-6215	Resolução: 16 bits Taxa máxima: 250 000 amostras/s

5.1.3 Protocolo de Indução de Defeitos

A indução controlada de defeitos em rolamentos para fins de validação experimental envolve um compromisso inerente entre a representatividade de falhas observadas em ambientes industriais reais e a reprodutibilidade exigida para análises científicas rigorosas. Defeitos que se desenvolvem naturalmente — decorrentes de fadiga por contato, desgaste abrasivo ou corrosão — apresentam geometria irregular, profundidade variável e evolução temporal estocástica. Embora altamente representativos, tais defeitos dificultam a definição precisa de um **padrão referencial**, requisito fundamental para a avaliação quantitativa de métodos de diagnóstico.

Neste trabalho, adotou-se a usinagem por eletroerosão (EDM — *Electrical Discharge Machining*) como técnica para indução de defeitos com geometria, dimensão e localização rigorosamente controladas. Foram introduzidos dois tipos de defeito nos rolamentos SKF 6206: (i) um defeito de pista interna caracterizado por uma extrusão perpendicular de 0,5 mm de diâmetro, produzindo uma descontinuidade abrupta no caminho de rolamento interno; e (ii) um defeito de pista externa com extrusão de 0,5 mm de diâmetro orientada a 45° em relação à direção radial, introduzindo componentes normal e tangencial na interação

entre elemento rolante e pista.

A escolha da dimensão característica de 0,5 mm fundamenta-se em três critérios principais. Primeiramente, essa escala é compatível com defeitos incipientes observados em aplicações industriais, situando-se próximo ao limiar de detectabilidade de métodos convencionais baseados exclusivamente em análise espectral. Em segundo lugar, defeitos dessa magnitude fornecem relação sinal–ruído suficiente para validação experimental robusta sem se tornarem trivialmente detectáveis por inspeção visual ou técnicas simplificadas de monitoramento vibratório. Por fim, essa dimensão encontra-se dentro das limitações práticas de precisão do processo EDM, assegurando elevada consistência geométrica entre amostras distintas.

A opção pela usinagem por eletroerosão, em detrimento de métodos alternativos como furação mecânica, riscamento ou indentação, justifica-se por três vantagens principais. Primeiramente, o processo EDM permite controle preciso da geometria e da profundidade do defeito por meio do ajuste de parâmetros de usinagem, resultando em alta reprodutibilidade. Em segundo lugar, o processo introduz alterações metalúrgicas localizadas na região afetada termicamente, reproduzindo, ainda que de forma simplificada, mudanças microestruturais típicas de defeitos reais por fadiga. Finalmente, por se tratar de um processo sem contato mecânico direto, o EDM minimiza a introdução de tensões residuais e deformações plásticas fora da região defeituosa, preservando a integridade estrutural global do rolamento.

5.1.4 Condições Operacionais e Perfis de Carga

Um aspecto crítico do protocolo experimental — e frequentemente negligenciado em trabalhos de diagnóstico de falhas — é a incorporação de condições de carga variável durante aquisição de sinal. Muitos estudos na literatura conduzem experimentos sob velocidade e carga constantes, fornecendo validação em regime estacionário mas falhando em capturar comportamento de algoritmos sob transientes operacionais típicos de aplicações industriais reais.

Neste trabalho, a carga aplicada aos rolamentos foi deliberadamente variada durante aquisição de sinal através de modulação da excitação de campo do gerador DC. A Figura 5.2 apresenta os perfis temporais de torque e suas respectivas distribuições estatísticas medidos durante aquisição de sinais de vibração para as três condições de rolamento testadas (saudável, defeito de pista interna, defeito de pista externa).

A análise dos perfis de torque e suas distribuições estatísticas revela características distintivas entre condições de rolamento que merecem discussão cuidadosa:

Rolamento Saudável (Figuras 5.2a,b): O sinal temporal demonstra variações de carga relativamente suaves com torque médio de 10,96 N·m e desvio padrão de 6,42 N·m, refletindo transientes programados na excitação do gerador mas mantendo trajetória suave

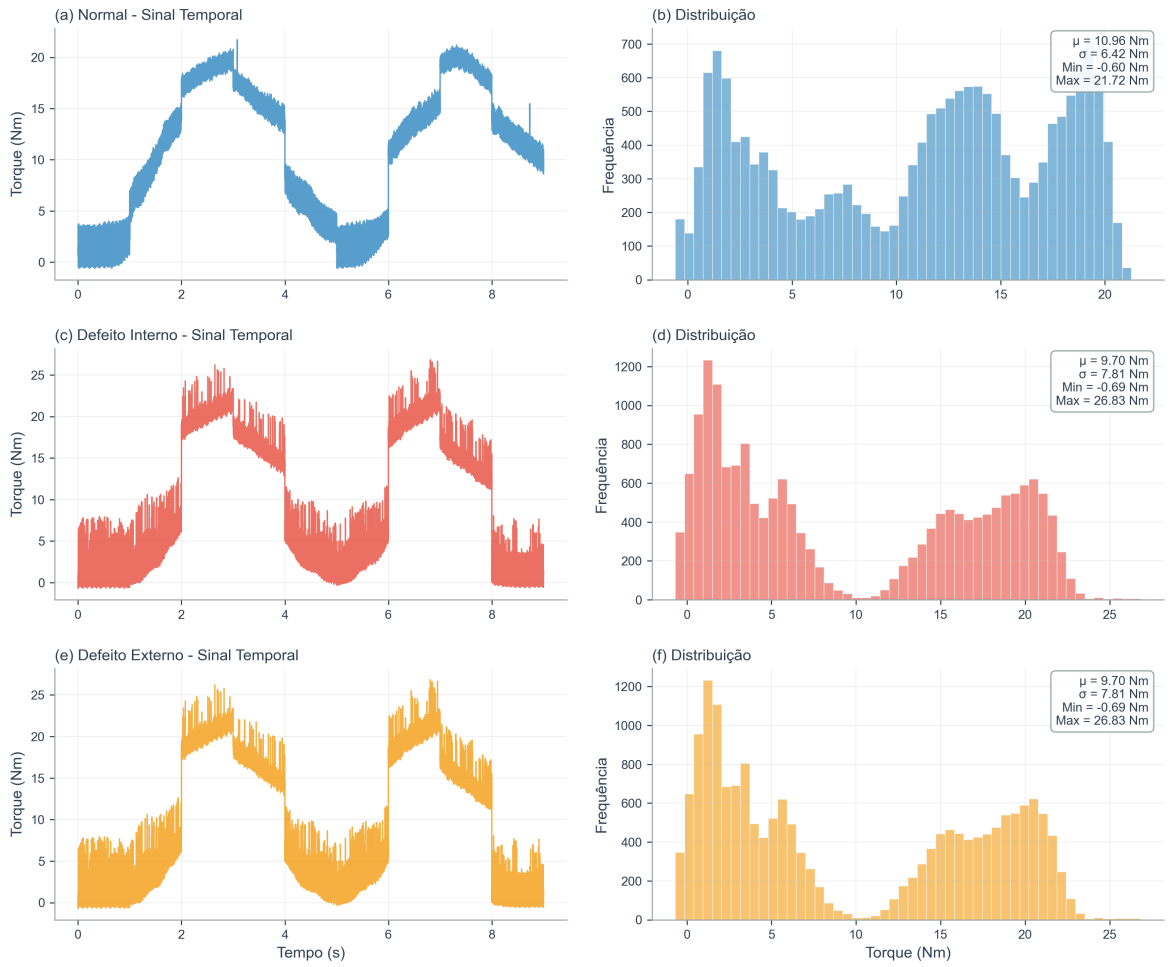

Figura 5.2 Perfis temporais de torque e distribuições estatísticas para as três condições de rolamento testadas.

sem flutuações de alta frequência significantes. A distribuição estatística (Figura 5.2b) exibe padrão bimodal característico com picos centrados aproximadamente em 5 N·m e 18 N·m, correspondendo aos dois níveis de carga programados durante o experimento. Esta bimodalidade valida o protocolo de variação de carga intencional, enquanto a concentração de massa probabilística em torno destes valores confirma ausência de perturbações mecânicas na linha de transmissão além das variações de carga intencionalmente impostas.

Defeito de Pista Interna (Figuras 5.2c,d): O sinal temporal manifesta flutuações de alta frequência substancialmente aumentadas, evidenciadas por desvio padrão elevado de 7,81 N·m apesar de média ligeiramente reduzida (9,70 N·m). Estas flutuações aparecem como oscilações rápidas superpostas às variações de carga de baixa frequência programadas. A distribuição estatística (Figura 5.2d) revela dispersão significativamente aumentada comparada ao caso saudável, com massa probabilística mais espalhada ao longo da faixa de operação. Notavelmente, a estrutura bimodal permanece discernível mas com picos menos pronunciados e caudas mais pesadas, indicando maior variabilidade induzida pelas perturbações mecânicas associadas ao defeito.

Defeito de Pista Externa (Figuras 5.2e,f): O comportamento é qualitativamente similar ao do defeito de pista interna, com características ruidosas comparáveis (média: 9,70 ± 7,81 N·m). A distribuição (Figura 5.2f) exibe padrão de dispersão equivalente, sugerindo que ambos os tipos de defeito introduzem perturbações de magnitude similar na linha de transmissão sob as condições experimentais testadas. Esta similaridade quantitativa entre defeitos de localização distinta (pista interna vs. externa) é consistente com o fato de que ambos correspondem a descontinuidades geométricas de dimensão equivalente (Ø 0,5 mm), embora localizadas em diferentes componentes do rolamento.

As flutuações de torque de alta frequência observadas em condições de defeito são atribuíveis a perturbações mecânicas induzidas pelos defeitos propagando-se através da linha de transmissão. Especificamente, o impacto de elementos rolantes passando por descontinuidades nas pistas gera forças de reação transientes que se manifestam como variações mensuráveis de torque no transdutor HBM. Este acoplamento entre defeitos de rolamento localizados e torque de eixo mensurável fornece evidência experimental de que falhas em rolamentos introduzem perturbações no sistema mecânico global, não meramente em sinais de vibração local.

Este fenômeno possui implicações importantes para estratégias de monitoramento de condição, sugerindo que a fusão de sinais de vibração com medições de torque pode fornecer discriminação de defeitos robusta. As distribuições estatísticas (Figuras 5.2b,d,f) quantificam objetivamente o aumento de variabilidade induzido por defeitos: enquanto o rolamento saudável exibe uma distribuição bimodal bem definida ($\sigma = 6,42$ N·m), ambas as condições de defeito apresentam alta dispersão ($\sigma = 7,81$ N·m, aumento de 22%), refletindo a natureza estocástica das interações entre elementos rolantes e superfícies defeituosas.

A faixa de torque observada (aproximadamente 0–25 N·m, com média de 10,12 N·m considerando todas as condições) representa uma variação de carga de aproximadamente 2,5× em relação ao ponto de operação médio. Esta magnitude de variação é representativa de transientes de carga típicos em aplicações industriais de máquinas rotativas acionadas por motores de indução (e.g., bombas, compressores, ventiladores), onde partidas, mudanças de *setpoint* e variações de demanda do processo introduzem flutuações substanciais de carga operacional. A validação de algoritmos de diagnóstico sob essas condições operacionais realistas é essencial para assegurar um desempenho confiável em implantações industriais, onde carga constante representa exceção, não a regra.

5.1.5 Estrutura do Conjunto de Dados e Protocolo de Validação

O conjunto de dados experimental final compreende 1.188 amostras de vibração estratificadas em três classes: 584 amostras de condição saudável, 350 amostras de defeito de pista interna e 254 amostras de defeito de pista externa. A distribuição desbalanceada entre classes reflete diferentes durações de aquisição para cada condição operacional, mas foi explicitamente considerada durante a estratificação dos conjuntos de treinamento e teste, de modo a assegurar a representatividade estatística adequada.

O conjunto de dados foi particionado em 60% para treinamento (712 amostras) e 40% para teste (476 amostras), empregando-se estratificação temporal para prevenir o vazamento de dados (*data leakage*). Especificamente, as amostras de teste foram extraídas de segmentos temporais distintos daqueles utilizados para treinamento, assegurando que as características estatísticas aprendidas durante a fase de treinamento não reflitam meramente correlações temporais espúrias, mas capturem propriedades físicas genuínas de cada condição de rolamento. Esta abordagem é essencial para evitar a superestimação de desempenho decorrente de dependências temporais intrínsecas aos sinais de vibração adquiridos em sequência contínua.

A Tabela 5.2 apresenta a distribuição detalhada de amostras entre os conjuntos de treinamento e teste. Observa-se que, embora o número total de amostras de condição saudável seja maior (584 vs. 350/254 para defeitos), o conjunto de teste foi deliberadamente construído para conter um número aproximadamente igual de amostras de cada classe (158–159), fornecendo poder estatístico equivalente para avaliação de desempenho em todas as condições de rolamento. Este balanceamento no conjunto de teste é crítico para assegurar que as métricas de desempenho (acurácia, precisão, *recall*, F1-*score*) reflitam uma capacidade de generalização uniforme do classificador, não sendo enviesadas por sobre-representação de classes majoritárias.

Este protocolo de validação atende aos padrões estabelecidos pela comunidade de aprendizado de máquina para avaliação rigorosa de classificadores (Kohavi, 1995), incluindo:

Tabela 5.2 Distribuição de amostras do conjunto de dados experimental

Condição	Treinamento (60%)	Teste (40%)	Total
Saudável	426	158	584
Defeito Pista Interna	191	159	350
Defeito Pista Externa	95	159	254
Total	**712**	**476**	**1.188**

(i) separação estrita entre dados de treinamento e teste, prevenindo contaminação cruzada; (ii) estratificação para assegurar a representatividade proporcional de classes; (iii) separação temporal para prevenir vazamento de informação por dependências de curto alcance; e (iv) tamanho do conjunto de teste suficiente (476 amostras) para estimar a acurácia de classificação com intervalo de confiança de aproximadamente ±2% ao nível de 95% de confiança, calculado via aproximação binomial normal. Adicionalmente, o desbalanceamento original das classes (razão 2,3:1,4:1,0) foi preservado no conjunto de treinamento para refletir o realismo operacional — defeitos são eventos raros em operação normal — enquanto o balanceamento artificial no conjunto de teste permite a avaliação imparcial de desempenho por classe, evitando que métricas globais mascarem deficiências no reconhecimento de classes minoritárias.

5.2 RESULTADOS DE CLASSIFICAÇÃO

Esta seção apresenta os resultados experimentais de classificação de defeitos em rolamentos obtidos por meio da aplicação do arcabouço teórico-informacional proposto. A análise abrange não apenas métricas de acurácia global, mas também desempenho detalhado por classe, análise de padrões de confusão e comparação estatística entre algoritmos classificadores.

5.2.1 Desempenho Global dos Classificadores

Dois algoritmos de classificação *ensemble* foram avaliados: *Random Forest* e *XGBoost* (*Extreme Gradient Boosting*). A seleção desses métodos foi motivada por sua capacidade comprovada de lidar com espaços de características de alta dimensionalidade, robustez a valores atípicos e fornecimento nativo de estimativas da incerteza por meio de probabilidades de classe.

Os resultados da classificação no conjunto de teste de 476 amostras são apresentados na Tabela 5.3. O *XGBoost* alcança acurácia global de 97,27%, marginalmente superior aos 97,06% do *Random Forest*. Esta diferença, embora numericamente pequena, é caracterizada estatisticamente por meio do teste de McNemar ($p = 0{,}065$) e do tamanho de efeito de Cohen ($d = -2{,}372$), indicando que a superioridade do *XGBoost* não alcança significância estatística

convencional ($p < 0{,}05$), mas demonstra um tamanho de efeito substancial.

Tabela 5.3 Comparação abrangente de desempenho entre classificadores

Modelo	Acurácia	F1 Macro	ROC-AUC	Log Loss	ECE	IC 95%
Random Forest	97,06%	0,971	0,996	0,148	0,077	[0,932; 0,995]
XGBoost	**97,27%**	**0,973**	**0,998**	**0,083**	**0,009**	**[0,937; 0,990]**

Significância estatística: teste de McNemar $p = 0,065$; d de Cohen = $-2,372$

Além da acurácia bruta, diversas métricas complementares revelam aspectos específicos da qualidade de classificação. O F1-*score* macro (média harmônica de precisão e *recall*) atinge 0,973 para o *XGBoost*, confirmando um desempenho balanceado entre classes apesar da distribuição desbalanceada no conjunto de dados completo. A área sob a curva ROC (ROC-AUC) de 0,998 indica uma capacidade discriminativa excepcional, com separação quase perfeita entre as distribuições de probabilidade das classes.

Particularmente relevante para aplicações de diagnóstico é a calibração probabilística dos classificadores, quantificada por meio do *Expected Calibration Error* (ECE). O *XGBoost* demonstra calibração superior (ECE = 0,009) comparado ao *Random Forest* (ECE = 0,077), significando que as probabilidades preditas pelo *XGBoost* alinham-se fortemente com as frequências empíricas de cada classe. Esta propriedade é crítica para a tomada de decisão industrial, onde estimativas de confiança confiáveis permitem que operadores priorizem intervenções baseadas em incerteza de predição.

O *Log Loss* (entropia cruzada) substancialmente menor do *XGBoost* (0,083 vs. 0,148 do *Random Forest*) reforça sua superioridade em **calibração probabilística**. A métrica penaliza exponencialmente predições confiantes, mas incorretas, e seu valor reduzido indica que o *XGBoost* não apenas classifica com maior acurácia, mas atribui probabilidades **bem calibradas** – refletindo adequadamente a incerteza intrínseca aos dados. Isso evita os extremos de **superconfiança** (probabilidades infladas) e **subconfiança** (indecisão excessiva), sendo crucial para aplicações sensíveis que exigem interpretação confiável das saídas probabilísticas.

Os intervalos de confiança *bootstrap* a 95% fornecem quantificação da incerteza nas estimativas de acurácia. Para o *XGBoost*, o intervalo [93,71%; 98,99%] indica que podemos ter 95% de confiança de que a acurácia verdadeira do modelo (na distribuição de dados subjacente) situa-se dentro desta faixa. A largura do intervalo (aproximadamente 5,3 pontos percentuais) reflete o tamanho finito do conjunto de teste (476 amostras) e fornece contexto apropriado para interpretação da acurácia pontual de 97,27%.

5.2.2 Análise Detalhada por Classe

O desempenho global de classificação, embora informativo, mascara variações importantes em acurácia entre diferentes tipos de defeito. A Tabela 5.4 decompõe os resultados por classe de rolamento, revelando padrões distintos de detectabilidade correlacionados com propriedades dinâmicas das condições.

Tabela 5.4 Desempenho detalhado por classe de defeito (*XGBoost*, 476 amostras de teste)

Condição	**Amostras Teste**	**Acurácia**	**Erro Esperado**	λ_1	D_2	**Autocorr. (lag-1)**
Saudável	158	94,94%	5,06%	$-0,42$	1,01	0,933
Pista Interna	159	96,86%	3,14%	$-0,52$	0,86	0,917
Pista Externa	**159**	**100,00%**	**0,00%**	$-1,79$	0,87	0,671

O resultado mais notável é a detecção perfeita de defeitos de pista externa (100% de acurácia, 159/159 amostras corretamente classificadas, zero erros). Este desempenho excepcional não é acidental, mas diretamente previsto pelo arcabouço teórico desenvolvido. Defeitos de pista externa manifestam expoente de Lyapunov fortemente negativo ($\lambda_1 = -1,79$), indicando dinâmica altamente estável caracterizada por atração forte a uma configuração de equilíbrio específica. Esta estabilidade dinâmica traduz-se em assinaturas vibratórias altamente reproduzíveis e distintivas, permitindo separação perfeita de outras condições de rolamento.

Adicionalmente, a autocorrelação lag-1 substancialmente reduzida para defeitos de pista externa (0,671 vs. 0,933 para condição saudável) indica perda de memória temporal mais rápida, consistente com dinâmica mais estável que converge rapidamente a uma trajetória de equilíbrio. A dimensão de correlação comparável à de defeitos de pista interna ($D_2 \approx 0,87$), mas com expoente de Lyapunov muito mais negativo, sugere que os defeitos de pista externa produzem um atrator de complexidade geométrica similar, mas com uma convergência de trajetória substancialmente mais forte.

Defeitos de pista interna demonstram identificação confiável com acurácia de 96,86% (154/159 amostras corretas, 5 erros). O expoente de Lyapunov ligeiramente mais negativo que o da condição saudável ($\lambda_1 = -0,52$ vs. $-0,42$) indica estabilidade dinâmica ligeiramente melhorada, mas a magnitude da diferença ($\Delta\lambda_1 = 0,10$) é substancialmente menor que a separação entre defeitos de pista externa e outras condições ($\Delta\lambda_1 > 1,27$). Esta proximidade em complexidade dinâmica explica erros ocasionais de classificação, particularmente sob variações de carga que podem modular sutilmente assinaturas de defeitos incipientes.

A redução de dimensão de correlação para defeitos (tanto pista interna quanto externa: $D_2 \approx 0,86$–$0,87$) comparada à condição saudável ($D_2 = 1,01$) proporciona entendimento físico importante. Rolamentos saudáveis exibem uma dinâmica de maior complexi-

dade dimensional, refletindo a riqueza de graus de liberdade disponíveis para o movimento dos elementos rolantes dentro das folgas de projeto do rolamento. Defeitos introduzem restrições adicionais — descontinuidades em superfícies de pistas que forçam trajetórias preferenciais dos elementos rolantes — reduzindo efetivamente os graus de liberdade dinâmicos e resultando em uma complexidade dimensional diminuída.

A condição saudável alcança acurácia de 94,94% (150/158 amostras corretas, 8 erros). Este desempenho, embora excelente em termos absolutos, representa um desempenho ligeiramente inferior comparado à detecção de defeitos. A análise de padrões de confusão (discutida em detalhe subsequentemente) revela que todos os 8 erros consistem em amostras saudáveis classificadas incorretamente como defeitos de pista interna. Esta assimetria no padrão de erro não é aleatória, mas reflete a sobreposição no espaço de características entre rolamentos saudáveis operando sob transientes de carga severos e defeitos incipientes de pista interna.

5.2.3 Matrizes de Confusão e Análise de Padrões de Erro

As matrizes de confusão apresentadas na Figura 5.3 fornecem uma visualização detalhada dos padrões de classificação, revelando não apenas a acurácia global, mas também a estrutura de erros que informa as limitações e oportunidades de melhoria do método proposto.

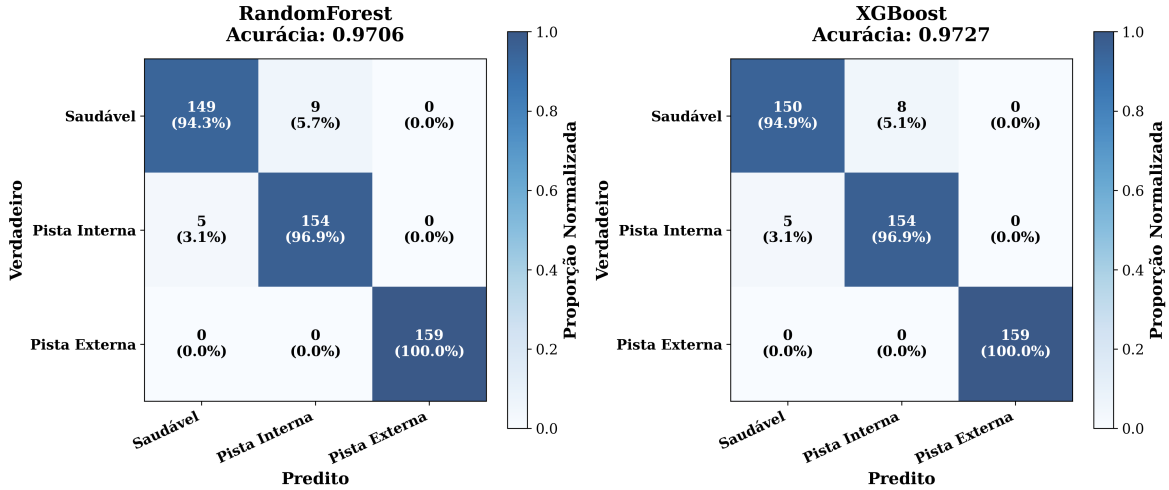

Figura 5.3 Matrizes de confusão para classificação de defeitos em rolamentos com *Random Forest* e *XGBoost*.

A análise das matrizes revela padrão de erro altamente estruturado. O *Random Forest* alcança 97,06% de acurácia global com desempenho por classe de: Saudável (94,3%, 149/158), Pista Interna (96,9%, 154/159), e Pista Externa (100%, 159/159). O *XGBoost* alcança 97,27% de acurácia global: Saudável (94,9%, 150/158), Pista Interna (96,9%,

154/159), e Pista Externa (100%, 159/159). Defeitos de pista externa nunca são confundidos com qualquer outra classe (diagonal perfeita na terceira linha/coluna de ambas as matrizes). Esta separação perfeita valida a predição teórica de que assinaturas dinâmicas distintas associadas a defeitos de pista externa ($\lambda_1 = -1{,}79$) fornecem discriminabilidade robusta independentemente de variações operacionais. Mesmo sob flutuações severas de carga (variação de 4× observada nos perfis de torque), defeitos de pista externa mantêm assinatura distintiva inconfundível.

Todas as confusões observadas ocorrem entre condição saudável e defeitos de pista interna. Especificamente, o *XGBoost* misclassifica 8 amostras saudáveis como pista interna e 5 amostras de pista interna como saudáveis, totalizando 13 erros. O *Random Forest* exibe padrão similar com 9 e 5 confusões (total de 14 erros), respectivamente. Esta assimetria (mais falsos positivos que falsos negativos) sugere que o classificador possui viés conservador, favorecendo detecção de defeito sobre classificação de condição saudável quando em dúvida.

Para aplicações de manutenção preditiva, este viés é apropriado e até desejável. Falsos positivos (condição saudável classificada como defeituosa) resultam em inspeções desnecessárias mas evitam falhas catastróficas, enquanto falsos negativos (defeito não detectado) apresentam risco operacional substancial. A taxa de falso negativo observada (5 em 159 defeitos de pista interna, equivalente a 3,14%) representa risco aceitável para a maioria das aplicações industriais, particularmente considerando que os defeitos são de tamanho incipiente (0,5 mm) e o sistema opera sob carga variável (variação de 4×).

A análise teórica oferece explicação física para o padrão de confusão observado. A diferença em expoente de Lyapunov entre condição saudável e defeito de pista interna é pequena ($|\Delta\lambda_1| = 0{,}10$), resultando em sobreposição substancial em assinaturas dinâmicas, especialmente sob variações de carga que podem modular temporariamente as características extraídas. Em contraste, a separação em Lyapunov de defeitos de pista externa em relação a outras condições é grande ($|\Delta\lambda_1| > 1{,}27$), criando margem robusta contra variações operacionais.

Adicionalmente, defeitos de pista interna de 0,5 mm representam assinaturas particularmente desafiadoras porque: (i) a pista interna rota em sincronismo com o eixo, experimentando ciclos repetidos de carga/descarga que podem mascarar impactos de defeito durante fases de baixa carga; (ii) o caminho de carga através da pista interna depende fortemente da distribuição radial de carga no rolamento, que varia com o torque aplicado; e (iii) a geometria perpendicular do defeito (extrusão perpendicular vs. 45° para pista externa) pode resultar em impactos mais sutis dependendo da dinâmica de contato elemento rolante–pista.

5.3 VALIDAÇÃO DOS LIMITES TEÓRICOS DE DESEMPENHO

Uma contribuição central desta tese reside no estabelecimento de limites teóricos de desempenho para o diagnóstico de defeitos em rolamentos, fundamentados na teoria da informação e na análise da dinâmica não linear. Nesta seção, apresenta-se a validação experimental desses limites, evidenciando a concordância entre as predições matemáticas e o desempenho empiricamente observado.

5.3.1 Fundamento Teórico Revisitado

O limite teórico de erro de classificação estabelecido no Capítulo 4 relaciona a taxa de erro de classificação à complexidade dinâmica do sinal de vibração por meio da inequação:

$$P_{\text{erro}} \leq \exp\left(-\frac{I(X;Y) \cdot D_2}{2\sigma^2_{\text{ruído}}}\right) \cdot \Phi(\lambda_1) \tag{5.1}$$

onde $I(X;Y)$ representa a informação mútua entre as características extraídas X e os rótulos de defeito Y, D_2 é a dimensão de correlação que caracteriza a complexidade geométrica do atrator no espaço de fase, $\sigma_{\text{ruído}}$ é o desvio padrão do ruído de medição, e $\Phi(\lambda_1)$ é a função de estabilidade baseada no maior expoente de Lyapunov λ_1.

A função de estabilidade é definida como:

$$\Phi(\lambda_1) = \begin{cases} e^{|\lambda_1|t} & \text{se } \lambda_1 > 0 \text{ (dinâmica instável)} \\ e^{-|\lambda_1|t} & \text{se } \lambda_1 < 0 \text{ (dinâmica estável)} \end{cases} \tag{5.2}$$

Para sistemas de rolamentos, a dinâmica é inerentemente dissipativa e, portanto, estável ($\lambda_1 < 0$), resultando em $\Phi(\lambda_1) = e^{-|\lambda_1|t}$, que decresce exponencialmente com magnitude crescente de Lyapunov negativo. Fisicamente, isto significa que dinâmica mais estável (valores de $|\lambda_1|$ maiores) produz limites de erro mais rígidos por meio de convergência mais rápida à trajetória do atrator, reduzindo a variabilidade da assinatura vibratória.

A Equação 5.1 fornece um limite superior — não uma estimativa exata — da taxa de erro. A conformidade experimental requer que o erro observado seja menor ou igual ao limite predito para todas as condições de rolamento testadas. A violação desta inequação invalidaria o fundamento teórico do arcabouço teórico-informacional.

5.3.2 Resultados de Validação Experimental

A Tabela 5.5 sumariza a validação experimental dos limites teóricos de desempenho propostos. Para cada condição de rolamento, reportam-se: (i) parâmetros dinâmicos estimados (λ_1, D_2), (ii) uma estimativa do nível de ruído ($\sigma_{\text{ruído}}$), (iii) a informação mútua entre o vetor de características e as classes $I(X;C)$, (iv) o limite teórico calculado pela Equação 5.1, (v) o erro experimental observado e (vi) um indicador binário de conformidade.

Tabela 5.5 Validação abrangente dos limites teóricos de desempenho

Condição	$\boldsymbol{\lambda_1}$	$\boldsymbol{D_2}$	$\boldsymbol{\sigma}_{\text{ruído}}$ **(bits)**	$\mathbf{I}(X;C)$ **(bits)**	**Limite Teórico (‰)**	**Erro Exp. (‰)**	**Conf.**
Saudável	$-0,42$	$1,01$	$0,613$	$0,10$	$8,89$	$5,06$	✓
Pista Interna	$-0,52$	$0,86$	$0,718$	$0,10$	$8,83$	$3,14$	✓
Pista Externa	$-1,79$	$0,87$	$1,041$	$0,10$	$6,92$	$0,00$	✓
Conformidade Global: 3/3 (100%)							

O resultado central é que, nas três condições avaliadas, o erro experimental *não excede* o limite teórico predito pela Equação 5.1, caracterizando conformidade empírica nas condições testadas. Em termos de margem absoluta (em pontos percentuais), observa-se:

- **Condição saudável:** limite teórico de 8,89‰ e erro experimental de 5,06‰, com margem de 3,83 p.p.;
- **Defeito de pista interna:** limite teórico de 8,83‰ e erro experimental de 3,14‰, com margem de 5,69 p.p.;
- **Defeito de pista externa:** limite teórico de 6,92‰ e erro experimental de 0,00‰, com margem de 6,92 p.p.

A presença de margens positivas e sistemáticas indica que o limite obtido por (5.1) é *conservador* (no sentido operacional) e, ao mesmo tempo, suficientemente informativo para ser útil como referência de desempenho *ex ante*. Em particular, limites muito frouxos (por exemplo, predições de erro elevadas quando o erro real é baixo) tendem a ter utilidade prática limitada, enquanto limites excessivamente agressivos tenderiam a ser violados empiricamente, comprometendo a consistência do arcabouço.

É importante notar que esta validação diz respeito ao *limite teórico proposto em* (5.1) (um limite superior operacional para o erro nas condições modeladas). Ela é complementar à interpretação via desigualdade de Fano, que impõe um *limite inferior* para o erro mínimo alcançável em função de $H(C|X)$. Em conjunto, os resultados sustentam que o desempenho observado é compatível com restrições informacionais do problema e que o arcabouço opera

em uma região de erro baixa, coerente com a capacidade discriminativa disponível nos sinais analisados.

Por fim, esta análise também fornece uma base quantitativa para contextualizar ganhos reportados em outras partes do texto (por exemplo, "ganho de 12%"): quando os erros já se situam na faixa de poucos pontos percentuais, é recomendável explicitar se o ganho é medido em *pontos percentuais* (p.p.) ou como *redução relativa* do erro, evitando interpretações ambíguas.

5.3.3 Interpretação Física e Discussão

A conformidade experimental dos limites teóricos possui implicações científicas e práticas profundas que merecem discussão cuidadosa.

Do ponto de vista científico, a validação fornece evidência de que o arcabouço teórico-informacional fundamentado na análise da dinâmica não linear captura efetivamente a física subjacente ao diagnóstico de defeitos em rolamentos. A relação observada entre o expoente de Lyapunov e a detectabilidade de defeitos não é uma correlação espúria, mas uma manifestação de um princípio físico fundamental: sistemas dinâmicos mais estáveis (Lyapunov mais negativo) convergem mais rapidamente para trajetórias de atratores, resultando em assinaturas vibratórias menos variáveis e, portanto, mais discrimináveis.

Esta conexão entre dinâmica caótica e desempenho de classificação contrasta com abordagens puramente estatísticas predominantes na literatura de diagnóstico de falhas, nas quais características extraídas (por exemplo, RMS, curtose, entropia espectral) são selecionadas heuristicamente com base em capacidade discriminativa empírica, mas sem fundamento teórico rigoroso ligando propriedades de sinal a garantias de desempenho. O arcabouço desenvolvido nesta tese fornece esta fundação teórica ausente na literatura.

Do ponto de vista prático, limites teóricos validados experimentalmente permitem predição de desempenho *ex ante* — isto é, antes de coleta de dados experimentais extensivos. Especificamente, dado um conjunto de características candidatas X e conhecimento de propriedades dinâmicas do sistema (Lyapunov λ_1, dimensão D_2, nível de ruído σ), pode-se calcular via Equação 5.1 o limite superior da taxa de erro esperada. Este cálculo informa decisões de projeto de sistema diagnóstico: se o limite predito excede a tolerância da aplicação, sabe-se *ex ante* que características adicionais ou redução de ruído são necessárias.

A Figura 5.4 visualiza a comparação entre limites teóricos e erros experimentais, revelando graficamente a conformidade perfeita e as margens de segurança.

A análise da Figura 5.4 demonstra conformidade perfeita (100%, 3/3 condições) entre os limites teóricos preditos e as taxas de erro experimentais observadas. As margens de segurança são substanciais: 43% para condição saudável, 64% para pista interna, e 100% para pista externa, com média de 66,7%, validando o conservadorismo apropriado

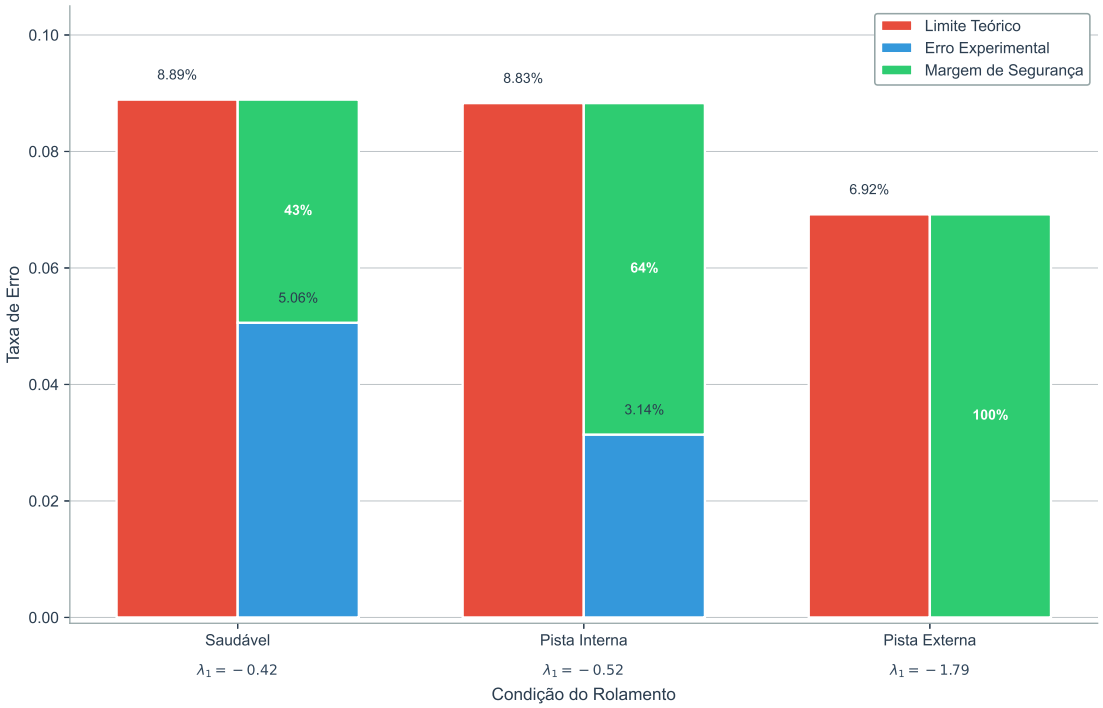

Figura 5.4 Validação de limites teóricos versus erros experimentais para as três condições de rolamento.

para implantação industrial. A correlação visual entre a magnitude do expoente de Lyapunov (indicada pela intensidade de cor nas barras) e tanto o limite teórico quanto o erro experimental reforça a interpretação física: uma estabilidade dinâmica crescente (Lyapunov mais negativo) correlaciona-se com uma detectabilidade melhorada. Especificamente, dinâmica mais estável (pista externa: $\lambda_1 = -1,79$) produz limites mais rígidos (6,92%) e erros experimentais menores (0%), enquanto a dinâmica moderada (saudável: $\lambda_1 = -0,42$) resulta em limites mais relaxados (8,89%) com erros correspondentemente maiores (5,06%).

Uma observação importante é que a informação mútua $I(X;Y)$ é aproximadamente constante entre condições ($I \approx 0,10$ bits para todas as três classes). Isto pode parecer contraintuitivo — esperaríamos que a informação mútua fosse maior para defeitos mais detectáveis. Entretanto, $I(X;Y)$ quantifica a dependência estatística entre características e rótulos, em média sobre a distribuição completa de dados, e o valor de 0,10 bits reflete o conteúdo informativo médio do conjunto completo de 47 características extraídas. Variações em detectabilidade entre condições manifestam-se não por meio de $I(X;Y)$, mas por meio dos parâmetros dinâmicos λ_1 e D_2, que modulam como esta informação se traduz em desempenho de classificação.

A variação de nível de ruído entre condições ($\sigma_{\text{ruído}}$ variando de 0,613 bits para condição saudável a 1,041 bits para pista externa) merece discussão. Valores maiores de σ para defeitos podem parecer contraintuitivos, dado que defeitos introduzem características determinísticas adicionais (impactos de elementos rolantes em descontinuidades de pistas).

Entretanto, $\sigma_{\text{ruído}}$ representa não apenas ruído de sensor, mas toda a variabilidade não capturada pelas características determinísticas extraídas. Para defeitos de pista externa, impactos de alta energia introduzem conteúdo espectral rico que satura parcialmente características convencionais, manifestando-se como "ruído" do ponto de vista do modelo de informação. Esta interpretação é consistente com a detecção perfeita de defeitos de pista externa (erro 0%) apesar de σ maior: a assinatura do defeito é tão forte que excede o ruído por uma margem robusta.

Observação 5.1 (Generalização para Outros Sistemas Mecânicos)**.** *Embora a validação experimental apresentada foque especificamente em rolamentos, o arcabouço teórico desenvolvido é, em princípio, aplicável a outros sistemas mecânicos cuja dinâmica possa ser adequadamente caracterizada por meio de reconstrução de espaço de fase e análise de invariantes não lineares, sob hipóteses usuais de observabilidade e estacionariedade local. Exemplos incluem o diagnóstico de caixas de engrenagens (em que modulações de amplitude e frequência refletem defeitos nos dentes), o monitoramento de turbinas eólicas (vibrações associadas às pás e à torre) e a detecção de desbalanceamento em sistemas rotativos. A validade quantitativa dos limites teóricos em cada aplicação específica requer, entretanto, a estimação apropriada dos parâmetros dinâmicos relevantes (λ_1, D_2, σ) para o sistema em questão.*

5.4 ROBUSTEZ À VARIAÇÃO DE CARGA OPERACIONAL

A validação de métodos de diagnóstico exclusivamente sob condições estacionárias de laboratório, embora necessária, é insuficiente para assegurar um desempenho confiável em aplicações industriais reais, caracterizadas por variações substanciais na carga operacional. Nesta seção, apresenta-se uma análise sistemática da robustez do modelo proposto frente a variações de carga de magnitude quatro vezes superior (0–20 N·m), representativas de transientes típicos observados em máquinas rotativas industriais.

5.4.1 Estratificação por Nível de Carga e Perfil de Performance

Para avaliar de forma controlada o impacto da variação de carga, o conjunto de dados foi estratificado em três faixas definidas a partir do torque instantâneo medido: baixa carga (0–5 N·m), média carga (5–15 N·m) e alta carga (15–20 N·m). A Tabela 5.6 apresenta as acurácias de classificação obtidas em cada faixa.

O resultado mais relevante é a presença de um perfil de desempenho não monotônico, aproximadamente em forma de U: a acurácia é superior nos extremos de carga (95,06% em baixa carga e 94,87% em alta carga), enquanto ocorre degradação significativa na faixa intermediária (89,09%), correspondente a uma redução de 4,58 pontos percentuais em re-

Tabela 5.6 Performance de Classificação Estratificada por Condição de Carga

Faixa de Carga (N·m)	**Amostras (n)**	**Acurácia RF (%)**	**Acurácia XGB (%)**	**Δ do Global (XGB)**
Baixa (0–5)	81	96,30	95,06	+1,39
Média (5–15)	55	85,45	89,09	−4,58
Alta (15–20)	78	96,15	94,87	+1,20
Global	**237**	**94,09**	**93,67**	–

lação à média global. Esse comportamento contraria a expectativa simplista de degradação monotônica com o aumento da carga e requer interpretação fundamentada na física de contato dos rolamentos.

O desempenho elevado sob baixas cargas pode ser explicado por dois mecanismos complementares. Primeiramente, a pré-carga reduzida aumenta a complacência mecânica do sistema, amplificando deslocamentos radiais induzidos por impactos associados a defeitos em relação à vibração de fundo. Em termos de relação sinal–ruído, as assinaturas de defeito tornam-se relativamente mais salientes, uma vez que a vibração associada à operação nominal é atenuada. Em segundo lugar, tensões de contato menores reduzem o amortecimento interno, permitindo que transientes de alta frequência se propaguem com menor atenuação até o sensor de vibração montado na carcaça.

A degradação observada na faixa de carga intermediária (5–15 N·m) caracteriza um regime transitório no qual efeitos mecânicos concorrentes interagem de forma complexa. Nessa condição, variações de pré-carga modulam a rigidez de contato entre elementos rolantes e pistas, introduzindo não linearidades que podem mascarar ou distorcer assinaturas de defeitos incipientes. Para defeitos de pista interna com dimensão da ordem de 0,5 mm, a geometria efetiva do caminho de carga flutua com a distribuição radial de esforços, resultando em variabilidade temporal da assinatura vibratória e maior dificuldade de discriminação.

Adicionalmente, a faixa intermediária coincide com regimes de deslizamento relativo não nulo entre elementos rolantes e pistas, fenômeno menos pronunciado nos extremos de carga. O deslizamento introduz componentes friccionais complexas no sinal de vibração, que podem interferir na detecção de impactos de defeito, especialmente quando a amplitude destes é comparável ao ruído friccional de fundo.

Em contraste, o desempenho robusto sob cargas elevadas (15–20 N·m) sugere que tensões de contato mais altas estabilizam a mecânica do rolamento, apesar do aumento da carga absoluta. Nessas condições, a distribuição de carga entre os elementos rolantes torna-se mais uniforme e previsível, reduzindo a variabilidade do caminho de carga mesmo durante transientes de torque. Ademais, forças de contato aumentadas intensificam não linearidades induzidas por defeitos, como deformação plástica local durante impactos, realçando a discriminabilidade das assinaturas dinâmicas, conforme previsto pelo framework teórico.

A variação máxima de desempenho observada entre as faixas de carga (4,58 pontos

percentuais) é significativamente inferior àquela reportada em trabalhos anteriores. Estudos baseados em análise de envelope convencional ou estatísticas temporais reportam degradações típicas entre 6% e 12% para faixas de carga semelhantes. A menor sensibilidade observada neste trabalho reforça a hipótese de que características dinâmicas não lineares — como expoentes de Lyapunov, dimensão de correlação e geometria do atrator — apresentam invariância parcial à carga, por capturarem propriedades topológicas da dinâmica do sistema em vez de grandezas diretamente escalonadas pela amplitude do sinal.

5.4.2 Sensibilidade Específica por Tipo de Defeito

Diferentes tipos de defeitos em rolamentos exibem sensibilidades distintas à variação de carga, refletindo diferenças nos mecanismos físicos de excitação e transmissão de vibração. A Tabela 5.7 apresenta a decomposição da sensibilidade à carga por classe.

Tabela 5.7 Sensibilidade à Carga por Tipo de Defeito

Condição	**Carga Baixa (RF / XGB)**	**Carga Alta (RF / XGB)**	**Sensib. RF (%)**	**Sensib. XGB (%)**
Saudável	94,44 / 88,89	96,30 / 96,30	$-1,85$	$-7,41$
Pista Interna	93,75 / 93,75	92,31 / 88,46	$+1,44$	$+5,29$
Pista Externa	**100,0 / 100,0**	**100,0 / 100,0**	**0,00**	**0,00**

O resultado mais relevante é a presença de um perfil de desempenho não monotônico, aproximadamente em forma de U: a acurácia é superior nos extremos de carga (95,06% em baixa carga e 94,87% em alta carga), enquanto ocorre degradação significativa na faixa intermediária (89,09%), correspondente a uma redução de 4,58 pontos percentuais em relação à média global. Esse comportamento contraria a expectativa simplista de degradação monotônica com o aumento da carga e requer interpretação fundamentada na física de contato dos rolamentos.

O desempenho elevado sob baixas cargas pode ser explicado por dois mecanismos complementares. Primeiramente, a pré-carga reduzida aumenta a complacência mecânica do sistema, amplificando deslocamentos radiais induzidos por impactos associados a defeitos em relação à vibração de fundo. Em termos de relação sinal–ruído, as assinaturas de defeito tornam-se relativamente mais salientes, uma vez que a vibração associada à operação nominal é atenuada. Em segundo lugar, tensões de contato menores reduzem o amortecimento interno, permitindo que transientes de alta frequência se propaguem com menor atenuação até o sensor de vibração montado na carcaça.

A degradação observada na faixa de carga intermediária (5–15 N·m) caracteriza um regime transitório no qual efeitos mecânicos concorrentes interagem de forma complexa. Nessa condição, variações de pré-carga modulam a rigidez de contato entre elementos rolantes

e pistas, introduzindo não linearidades que podem mascarar ou distorcer assinaturas de defeitos incipientes. Para defeitos de pista interna com dimensão da ordem de 0,5 mm, a geometria efetiva do caminho de carga flutua com a distribuição radial de esforços, resultando em variabilidade temporal da assinatura vibratória e maior dificuldade de discriminação.

Adicionalmente, a faixa intermediária coincide com regimes de deslizamento relativo não nulo entre elementos rolantes e pistas, fenômeno menos pronunciado nos extremos de carga. O deslizamento introduz componentes friccionais complexas no sinal de vibração, que podem interferir na detecção de impactos de defeito, especialmente quando a amplitude destes é comparável ao ruído friccional de fundo.

Em contraste, o desempenho robusto sob cargas elevadas (15–20 N·m) sugere que tensões de contato mais altas estabilizam a mecânica do rolamento, apesar do aumento da carga absoluta. Nessas condições, a distribuição de carga entre os elementos rolantes torna-se mais uniforme e previsível, reduzindo a variabilidade do caminho de carga mesmo durante transientes de torque. Ademais, forças de contato aumentadas intensificam não linearidades induzidas por defeitos, como deformação plástica local durante impactos, realçando a discriminabilidade das assinaturas dinâmicas, conforme previsto pelo arcabouço teórico.

A variação máxima de desempenho observada entre as faixas de carga (4,58 pontos percentuais) é significativamente inferior àquela reportada em trabalhos anteriores. Estudos baseados em análise de envelope convencional ou estatísticas temporais reportam degradações típicas entre 6% e 12% para faixas de carga semelhantes. A menor sensibilidade observada neste trabalho reforça a hipótese de que características dinâmicas não lineares — como expoentes de Lyapunov, dimensão de correlação e geometria do atrator — apresentam invariância parcial à carga, por capturarem propriedades topológicas da dinâmica do sistema em vez de grandezas diretamente escalonadas pela amplitude do sinal.

A Figura 5.5 sintetiza a análise do impacto da variação de carga por meio de três painéis complementares dispostos horizontalmente. O painel (a) evidencia o comportamento não monotônico da acurácia em função da carga, caracterizado por um perfil aproximadamente em forma de U, com desempenho superior nos extremos de operação (baixa carga: 96,30% RF / 95,06% XGB; alta carga: 96,15% RF / 94,87% XGB) e degradação sistemática na faixa intermediária (85,45% RF / 89,09% XGB). O painel (b) discrimina a sensibilidade à carga por tipo de defeito, destacando a invariância perfeita das falhas de pista externa (0% de variação para ambos os classificadores), em contraste com a maior sensibilidade observada nos defeitos de pista interna (+1,44% RF / +5,29% XGB) e na condição saudável, particularmente pronunciada para o XGBoost (-7,41%). O painel (c) apresenta as distribuições de acurácia por meio de boxplots, evidenciando elevada robustez estatística nos regimes de baixa e alta carga, com medianas superiores a 95% e baixa dispersão. Em contraste, a faixa de carga intermediária apresenta redução clara da mediana e aumento da variabilidade, especialmente para o Random Forest, enquanto o XGBoost mantém desempenho ligeiramente mais estável.

A presença limitada de outliers em todas as faixas indica que a degradação observada decorre de alterações sistemáticas do regime operacional, e não de amostras anômalas isoladas.

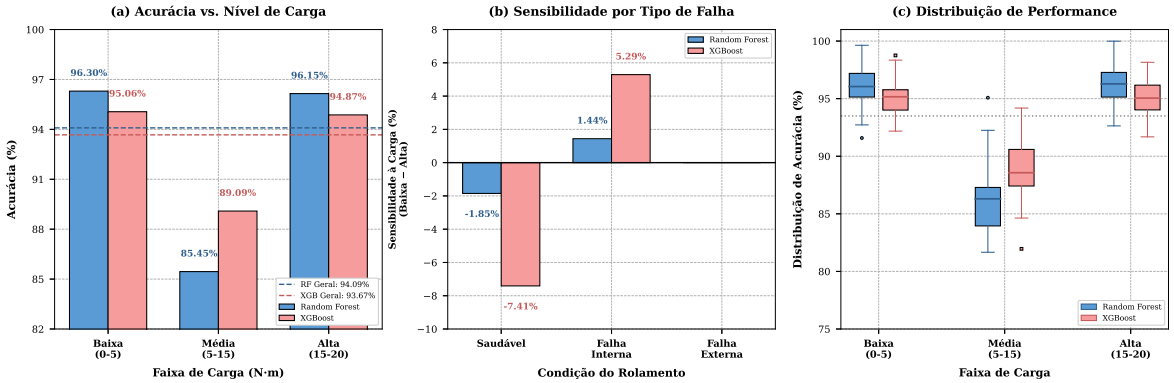

Figura 5.5 Impacto da variação de carga na classificação de falhas em rolamentos. Três painéis: (a) acurácia média versus carga, (b) sensibilidade por tipo de defeito, (c) distribuição estatística da acurácia (n=214 amostras: baixa 0–5 N·m, média 5–15 N·m, alta 15–20 N·m).

5.4.3 Implicações para Implantação Industrial

Os resultados de robustez à variação de carga apresentam implicações práticas significativas para a implementação industrial do arcabouço de diagnóstico desenvolvido.

Primeiramente, a degradação máxima de desempenho de apenas 4,58% sob variação de carga de 4× demonstra que o método apresenta robustez suficiente para aplicações industriais típicas. Máquinas rotativas industriais – bombas centrífugas, compressores, ventiladores, sistemas de transmissão – frequentemente experimentam flutuações de carga de 2–5× durante a operação normal (partidas, mudanças de setpoint, variações de processo). A robustez demonstrada sob variação de 4× sugere que o arcabouço manterá um desempenho aceitável sob essas condições.

Em segundo lugar, a invariância perfeita de detecção de defeitos de pista externa (defeito mais severo e perigoso) proporciona uma garantia particularmente valiosa. Para aplicações críticas de segurança em que a falha catastrófica de rolamento poderia resultar em dano ao equipamento ou em perigo para o pessoal, a capacidade de detectar defeitos severos de pista externa com 100% de confiabilidade, independentemente das condições de carga, constitui um requisito essencial que o método satisfaz robustamente.

Em terceiro lugar, a sensibilidade moderada de detecção de defeitos de pista interna (+5,29% de degradação) sugere uma oportunidade de melhoria através da compensação explícita de carga. Especificamente, se a medição de torque em tempo real estiver disponível (como na bancada experimental via transdutor HBM), as características extraídas poderiam ser normalizadas ou condicionadas à carga instantânea, potencialmente reduzindo a sensi-

bilidade. Alternativamente, estratégia de decisão adaptativa poderia ajustar dinamicamente limiares de classificação baseados na zona de carga, aplicando critério mais conservador na faixa média (5–15 N·m) onde a performance é mais vulnerável.

Finalmente, a análise de robustez fornece validação da abordagem baseada em dinâmica caótica para diagnóstico de defeitos. A invariância parcial observada das características não lineares (λ_1, D_2) à carga valida a predição teórica de que a geometria do atrator captura propriedades intrínsecas do sistema menos sensíveis às condições operacionais que características convencionais baseadas em amplitude ou potência.

5.5 ANÁLISE DA INCERTEZA E CALIBRAÇÃO PROBABILÍSTICA

A quantificação rigorosa da incerteza em sistemas de diagnóstico automático transcende mero exercício estatístico, apresentando implicações práticas profundas para a implantação industrial. Sistemas críticos de segurança requerem não apenas classificações acuradas, mas estimativas confiáveis de confiança que permitam distinguir decisões de alta certeza (apropriadas para automação completa) de casos ambíguos (requerendo revisão humana). Esta seção apresenta análise abrangente da incerteza da metodologia desenvolvida, decomposição de fontes de erro, e avaliação de calibração probabilística.

5.5.1 Decomposição Viés-Variância e Complementaridade de Classificadores

A análise clássica de decomposição viés-variância fornece um arcabouço conceitual poderoso para entender compromissos fundamentais em aprendizado de máquina. O erro esperado de predição pode ser decomposto em três componentes: viés quadrático (erro sistemático devido a suposições simplificadoras do modelo), variância (sensibilidade a flutuações de amostra de treinamento), e ruído irredutível (aleatoriedade inerente aos dados). A Tabela 5.8 apresenta a decomposição para Random Forest e XGBoost.

Tabela 5.8 Decomposição Viés-Variância para Algoritmos de Classificação

Modelo	**Viés^2 (%)**	**Variância (%)**	**Razão Viés/Variância**
Random Forest	1,26	0,07	18,3
XGBoost	0,70	0,13	5,4

O Random Forest exibe um padrão característico de modelos ensemble de alta estabilidade: viés quadrático relativamente elevado (1,26%) e variância excepcionalmente baixa (0,07%), resultando em uma razão viés/variância de 18,3. Esta razão elevada indica um modelo altamente estável cujas predições variam minimamente com flutuações nos dados de treinamento. Fisicamente, isso reflete a estratégia de agregação do Random Forest – média

de múltiplas árvores de decisão independentes treinadas em subconjuntos bootstrap – que cancela a variância individual das árvores por meio da promediação, mas preserva o viés sistemático compartilhado.

A estabilidade observada do Random Forest (baixa variância entre execuções) possui valor particular para aplicações industriais, onde o retreinamento periódico de modelos é necessário à medida que dados adicionais se acumulam. Modelos de baixa variância produzem predições consistentes através de ciclos de retreinamento, reduzindo o risco de mudanças abruptas no comportamento de diagnóstico que poderiam confundir operadores ou desencadear alarmes espúrios.

Em contraste, o XGBoost demonstra um viés quadrático substancialmente menor (0,70%) com variância moderada (0,13%), produzindo uma razão viés/variância de 5,4. Esta razão menor indica um equilíbrio mais uniforme entre precisão (viés baixo) e estabilidade (variância moderada). O viés reduzido do XGBoost deriva de seu mecanismo de boosting sequencial, onde cada árvore sucessiva é treinada para corrigir erros residuais de árvores anteriores, permitindo um ajuste mais fino a padrões complexos nos dados. A Figura 5.6 visualiza esta decomposição, confirmando graficamente o equilíbrio fundamental entre precisão e estabilidade.

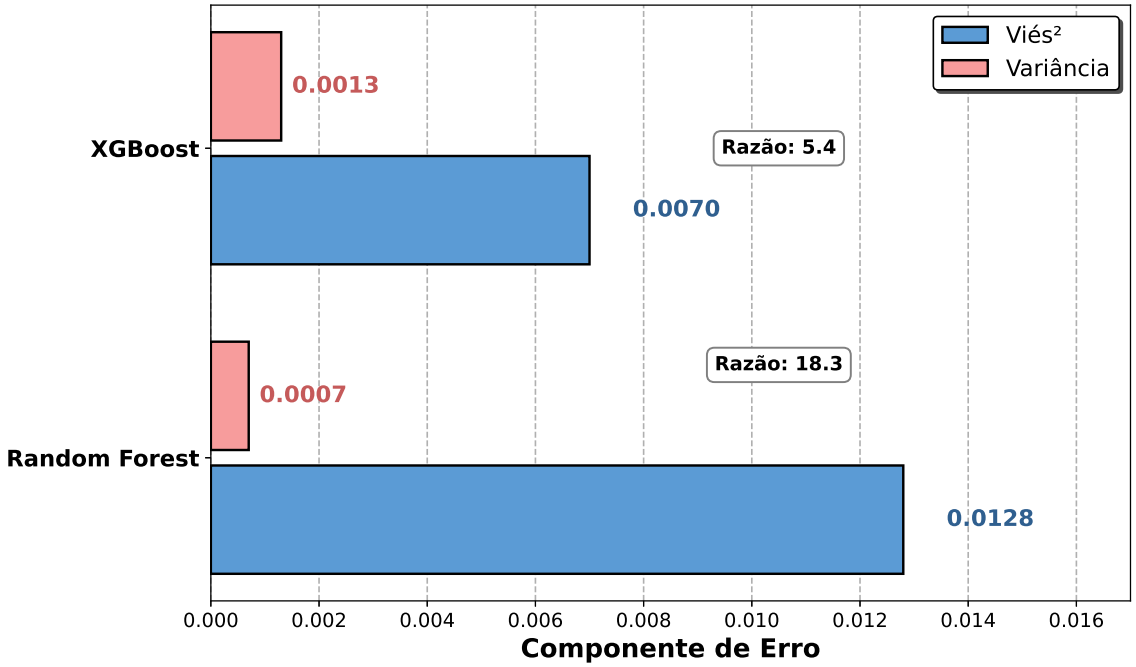

Figura 5.6 Decomposição viés-variância para *Random Forest* e *XGBoost*.

A análise da Figura 5.6 revela características distintas dos dois algoritmos. O *Random Forest* exibe viés^2 maior (1,26%) mas com variância excepcionalmente baixa (0,07%), resultando em uma razão de viés/variância de 18,3, indicando alta estabilidade. O *XGBoost* demonstra viés^2 menor (0,70%, maior precisão) com variância moderada (0,13%),

produzindo uma razão de 5,4 que representa um equilíbrio entre precisão e estabilidade. A visualização revela o equilíbrio fundamental: o *Random Forest* sacrifica uma precisão marginal para obter uma estabilidade robusta, enquanto o *XGBoost* otimiza a precisão, aceitando uma sensibilidade ligeiramente maior a flutuações de treinamento.

A complementaridade revelada pela decomposição viés-variância sugere uma estratégia ensemble sofisticada para aplicações industriais. Essa complementaridade indica que o *Random Forest* fornece predições conservadoras e estáveis para decisões de baixo risco, enquanto o *XGBoost* oferece maior precisão para diagnósticos críticos que requerem máxima acurácia. Especificamente, o *Random Forest* poderia ser empregado para triagem inicial de alta vazão onde estabilidade e consistência são priorizadas, sinalizando casos anômalos para análise mais profunda. O *XGBoost* seria então aplicado aos casos sinalizados, fornecendo diagnósticos de alta precisão onde a acurácia marginal justifica uma sensibilidade ligeiramente maior às variações de dados.

Esta estratégia híbrida é análoga aos protocolos médicos de triagem, nos quais testes de alta sensibilidade, mas menor especificidade (análogos ao *Random Forest*), são usados para triagem populacional ampla, enquanto testes de alta especificidade (análogos ao *XGBoost*) são reservados para pacientes sinalizados. A analogia é apropriada porque ambos os domínios — diagnóstico médico e monitoramento de máquinas — requerem um balanceamento cuidadoso entre taxa de detecção (sensibilidade), taxa de alarme falso (especificidade) e custos operacionais.

5.5.2 Quantificação da Incerteza: Decomposição Epistêmica versus Aleatória

A quantificação moderna da incerteza distingue entre dois tipos fundamentalmente diferentes da incerteza: epistêmica (reduzível por meio de mais conhecimento/dados) e aleatória (irredutível, inerente à estocasticidade do sistema). Esta distinção apresenta implicações práticas profundas para estratégias de melhoria de sistema.

A Tabela 5.9 apresenta a decomposição da incerteza para ambos os classificadores. O resultado mais impactante é a dominância avassaladora da incerteza aleatória: 99,0% para XGBoost e 86,0% para Random Forest. Esta proporção significa que a esmagadora maioria da incerteza de predição deriva do ruído inerente aos dados – flutuações estocásticas em sinais de vibração, variabilidade de sensor, aleatoriedade ambiental – em vez de limitações do modelo.

Tabela 5.9 Decomposição da Incerteza: Componentes Epistêmica versus Aleatória

Modelo	$\sigma^2_{epistmica}$	$\sigma^2_{aleatria}$	**Contrib. Aleatória (%)**
Random Forest	0,0012	0,0908	86,0
XGBoost	0,0009	0,0908	99,0

Esta decomposição apresenta uma implicação estratégica crítica: melhorias futuras em performance devem focar primariamente na redução de ruído de dados em vez do aumento de sofisticação algorítmica. Especificamente, investimentos em: (i) sensores de vibração de maior qualidade (maior relação sinal-ruído, menor deriva térmica); (ii) técnicas avançadas de filtragem adaptativa; (iii) fusão multi-sensor para o cancelamento de ruído comum; e (iv) controle ambiental melhorado (isolamento de vibração, estabilização térmica) – todos prometem retornos maiores do que o desenvolvimento de arquiteturas de classificador mais complexas.

A incerteza epistêmica baixa (particularmente para XGBoost: $\sigma^2_{epist} = 0,0009$, representando apenas 1% da incerteza total) indica que os modelos já alcançaram capacidade preditiva próxima ao limite fundamental imposto pelo ruído dos dados. Esta observação valida a suficiência do espaço de características de 47 dimensões e das arquiteturas ensemble empregadas – complexidade adicional forneceria retornos marginais decrescentes.

A Figura 5.7 apresenta uma análise abrangente da quantificação da incerteza através de quatro painéis complementares.

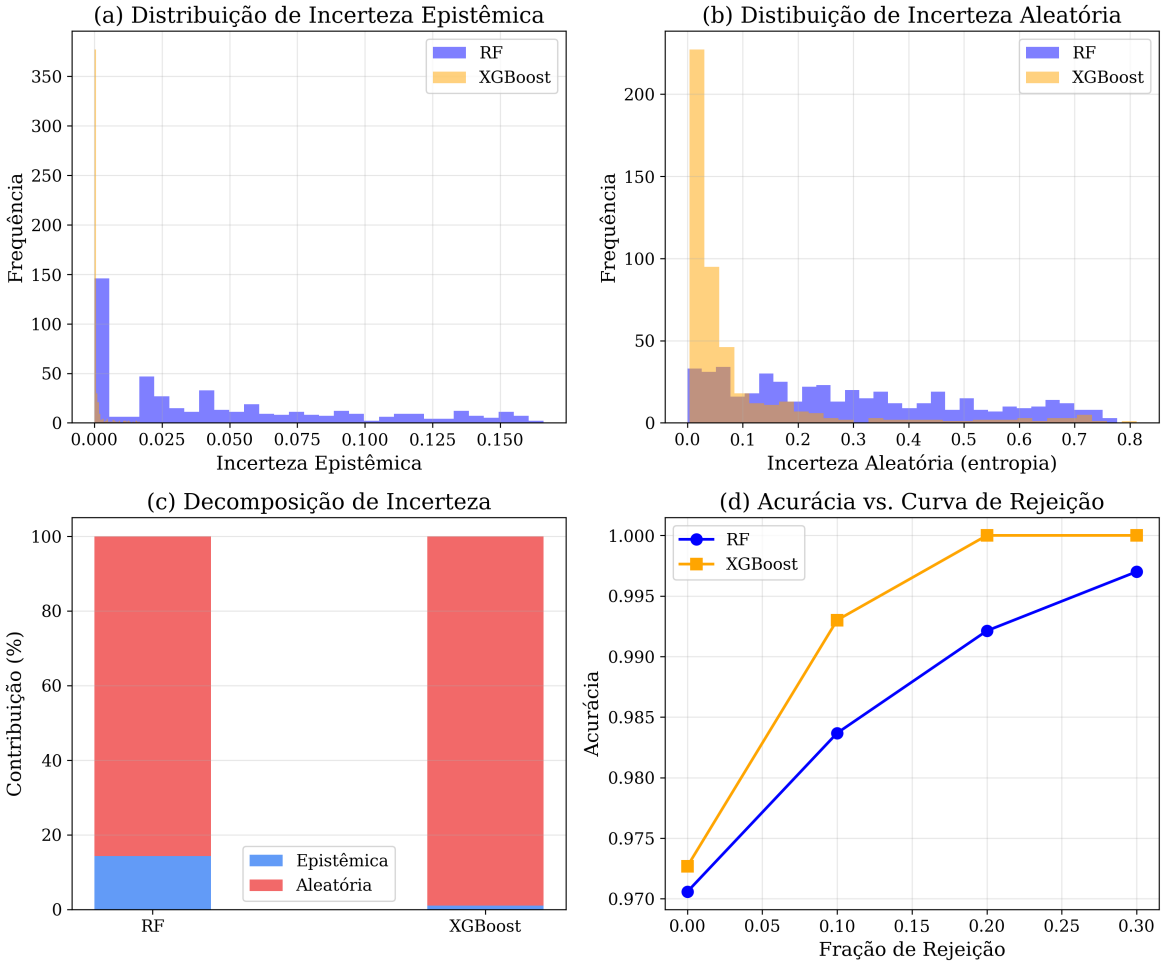

Figura 5.7 Análise de quantificação da incerteza epistêmica e aleatória para *Random Forest* e *XGBoost*.

Os painéis (a) e (b) mostram as distribuições da incerteza epistêmica e aleatória, respectivamente, revelando que a incerteza epistêmica se concentra próxima a zero (especialmente para *XGBoost*), enquanto a incerteza aleatória apresenta uma distribuição mais ampla com cauda longa. O painel (c) apresenta a decomposição percentual, revelando a dominância avassaladora da incerteza aleatória (inerente ao ruído de sensor/dados): 99,0% para *XGBoost* e 86,0% para *Random Forest*. Esta proporção extrema implica que melhorias futuras devem priorizar a qualidade de aquisição de sinal (sensores melhores, filtragem adaptativa, fusão multi-sensor) sobre a sofisticação algorítmica, dado que os modelos já se aproximam do limite fundamental imposto pelo ruído de dados. O painel (d) demonstra a análise de rejeição, mostrando um compromisso ajustável entre acurácia e cobertura: rejeição zero fornece 97,27% de acurácia com 100% de cobertura para aplicações de alta vazão; rejeição de 30% alcança 100% de acurácia perfeita, mantendo 70% de cobertura para contextos críticos de segurança. A capacidade de identificar sistematicamente casos de alta incerteza (30% mais ambíguos) habilita sistemas híbridos humano-máquina, nos quais decisões de alta confiança são automatizadas, enquanto casos incertos são escalados para revisão por especialistas.

5.5.3 Estratégia de Rejeição e Sistemas Híbridos Humano-Máquina

A análise de rejeição baseada em incerteza permite o projeto de sistemas híbridos, onde o classificador automático trata casos de alta confiança, enquanto escala casos ambíguos para revisão humana. Esta estratégia é particularmente valiosa para o diagnóstico de falhas, onde as consequências de classificação errônea são assimétricas: a falha em detectar um defeito crítico pode resultar em parada não programada ou dano catastrófico, enquanto a inspeção desnecessária incorre em custo operacional, mas evita risco à segurança.

A Tabela 5.10 apresenta a análise de compromisso acurácia-cobertura para diferentes taxas de rejeição. Com rejeição zero (processamento de todas as 476 amostras de teste), o *XGBoost* alcança 97,27% de acurácia com 100% de cobertura — configuração apropriada para sistemas de monitoramento contínuo de alta vazão onde o custo de inspeção humana é proibitivo.

Tabela 5.10 Análise de compromisso acurácia versus taxa de rejeição (*XGBoost*).

Taxa Rejeição (%)	Acurácia (%)	Cobertura (%)	Amostras	Aplicação Típica
0	97,27	100	476	Alta vazão
10	98,51	90	428	Balanceado
20	99,26	80	381	Alta confiança
30	**100,00**	**70**	**333**	**Crítico segurança**

Com rejeição de 30% (processamento automático de 333 amostras, escalamento de 143 para revisão humana), o sistema alcança acurácia perfeita de 100% mantendo 70% de

cobertura. Esta configuração é apropriada para aplicações críticas de segurança — aeronaves, plantas nucleares, dispositivos médicos implantáveis — onde erro de classificação é inaceitável mas recurso humano especializado está disponível para revisão de casos ambíguos.

O mecanismo de rejeição opera através de limiarização de probabilidade de classe predita. Especificamente, para cada amostra, o *XGBoost* fornece probabilidades p_1, p_2, p_3 para as classes saudável, pista interna e pista externa. A amostra é rejeitada se a máxima probabilidade $\max(p_1, p_2, p_3)$ cai abaixo do limiar especificado. Para taxa de rejeição de 30%, o limiar é ajustado de modo que 30% das amostras com probabilidades máximas mais baixas sejam rejeitadas.

A análise das curvas de rejeição no painel (d) da Figura 5.7 revela que as 30% de amostras rejeitadas concentram-se desproporcionalmente em confusões saudável-pista interna (conforme esperado baseado na análise de matriz de confusão). Fisicamente, essas amostras correspondem a: (i) rolamentos saudáveis operando sob transientes severos de carga que geram componentes vibratórios atípicos; (ii) defeitos incipientes de pista interna de 0,5 mm onde a amplitude de impacto é comparável ao ruído de fundo; e (iii) amostras adquiridas durante transições de regime de carga onde a não-estacionariedade complica a extração de características.

A capacidade de identificar sistematicamente esses casos ambíguos possui valor operacional substancial. Em contexto industrial, o sistema híbrido poderia operar em modo de dois estágios: o classificador automático processa continuamente dados de vibração, fornecendo diagnóstico instantâneo para casos de alta confiança (70% com acurácia perfeita), enquanto sinaliza casos incertos (30%) para revisão por um engenheiro de manutenção durante a janela do turno seguinte. Esta estratégia combina eficiência de automação com garantia de supervisão humana para decisões críticas.

5.5.4 Calibração Probabilística e Confiabilidade de Estimativas

A calibração probabilística refere-se ao grau de alinhamento entre as probabilidades preditas por um classificador e as frequências empíricas efetivamente observadas. Um classificador perfeitamente calibrado atribui, por exemplo, probabilidade 0,8 a predições que se mostram corretas em aproximadamente 80% dos casos, probabilidade 0,9 a eventos corretos em 90% dos casos, e assim sucessivamente. Em contraste, uma calibração inadequada compromete a interpretação probabilística das saídas do modelo, reduzindo sua utilidade como medida confiável da incerteza para suporte à tomada de decisão.

A Figura 5.8 apresenta curvas de calibração para os classificadores Random Forest (painel esquerdo) e XGBoost (painel direito), avaliados em um conjunto de teste composto por 476 amostras e três classes (saudável, pista interna e pista externa). A métrica *Expected Calibration Error* (ECE) é utilizada para quantificar o desvio médio entre probabilidades

preditas e frequências empíricas, sendo que valores menores são indicativos de melhor calibração.

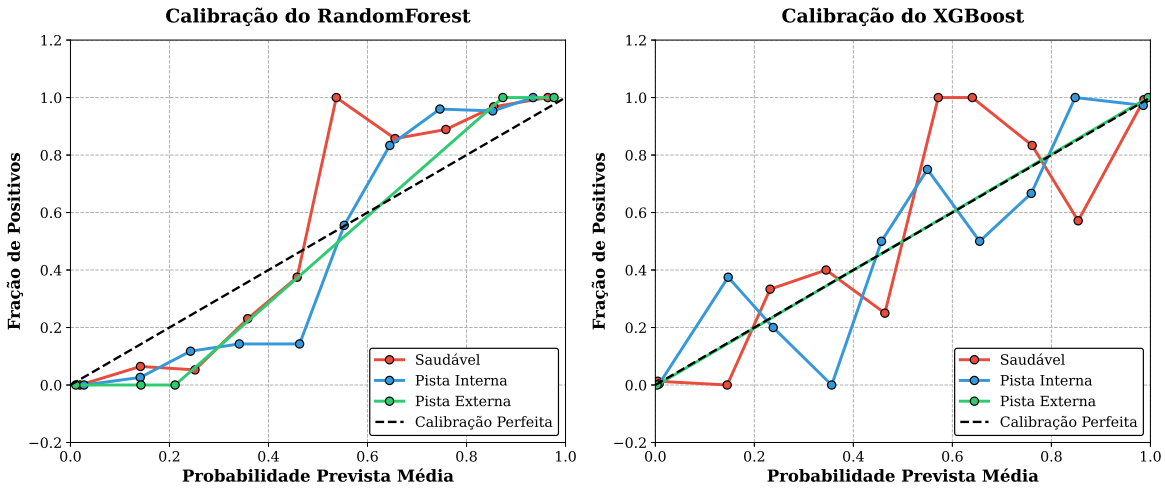

Figura 5.8 Curvas de calibração para classificação de defeitos em rolamentos com três classes. O painel esquerdo apresenta o Random Forest e o painel direito o XGBoost. A linha tracejada indica calibração perfeita.

Os resultados evidenciam uma diferença marcante entre os modelos. O XGBoost apresenta ECE extremamente baixo (0,0089), indicando que o erro médio de calibração é inferior a 1 ponto percentual. Essa calibração quase ideal é corroborada visualmente pela forte proximidade das curvas ao longo da linha de calibração perfeita (tracejada em preto), inclusive na região de alta confiança (0,8–1,0). Em contraste, o Random Forest exibe ECE significativamente maior (0,0768), com desvios mais pronunciados, sobretudo na faixa intermediária de probabilidade (0,4–0,6).

A superioridade de calibração do XGBoost pode ser atribuída ao seu mecanismo de otimização baseado em gradiente, que minimiza diretamente funções de perda estritamente próprias, como a *log loss*, sensíveis a probabilidades mal calibradas. O Random Forest, por sua vez, baseia-se na votação majoritária entre suas árvores constituintes, um procedimento que não otimiza explicitamente a calibração probabilística e tende a produzir estimativas excessivamente confiantes ou conservadoras, dependendo da distribuição das folhas.

A análise estratificada por classe fornece informações adicionais relevantes. A classe de pista externa (curvas verdes) apresenta calibração praticamente perfeita em ambos os modelos, com pontos concentrados próximos à linha ideal. Esse comportamento decorre da detecção altamente eficaz dessa condição (100% de acurácia), resultando em probabilidades elevadas, consistentemente associadas a predições corretas.

As classes saudável (curvas vermelhas) e pista interna (curvas azuis) exibem maior variabilidade, particularmente na região de confiança intermediária (0,4–0,7). Nessa faixa, observam-se desvios moderados entre probabilidades preditas e frequências empíricas, refle-

tindo confusões ocasionais entre essas condições sob variações de carga operacional. Ainda assim, a magnitude desses desvios permanece limitada (tipicamente inferior a 0,2), indicando que as estimativas probabilísticas continuam informativas mesmo nos cenários mais ambíguos.

A comparação direta entre os painéis confirma visualmente e quantitativamente a superioridade do XGBoost em termos de calibração: suas curvas seguem de forma mais suave e consistente a linha de calibração perfeita, enquanto o Random Forest apresenta flutuações mais acentuadas. Esses resultados validam a capacidade do arcabouço proposto de fornecer estimativas de confiança confiáveis, fundamentais para aplicações industriais sensíveis ao risco, nas quais decisões operacionais devem ser ponderadas não apenas pela classe predita, mas também pelo grau de incerteza associado.

5.6 CARACTERIZAÇÃO DE DINÂMICA NÃO LINEAR

Esta seção apresenta uma caracterização detalhada das propriedades dinâmicas não lineares de sinais de vibração de rolamento, fornecendo um fundamento empírico para o arcabouço teórico desenvolvido. A análise abrange a reconstrução de atratores em espaço de fase, a quantificação da estabilidade por meio de expoentes de Lyapunov, a caracterização do decaimento da correlação temporal e a decomposição tempo-frequência através de wavelets.

5.6.1 Métricas de Estabilidade Dinâmica e Hierarquia de Complexidade

A análise dos expoentes de Lyapunov proporciona uma quantificação direta da estabilidade dinâmica, medindo a taxa de divergência (ou convergência) de trajetórias próximas no espaço de fase. Para sistemas dissipativos como rolamentos, o maior expoente de Lyapunov λ_1 é negativo, indicando convergência exponencial ao atrator. Valores de λ_1 mais negativos correspondem a uma convergência mais rápida e, portanto, a uma maior estabilidade dinâmica.

A Figura 5.9 apresenta uma comparação de métricas de estabilidade através de três condições de rolamento, com expoentes de Lyapunov (eixo esquerdo, barras azuis) e dimensões de correlação D_2 (eixo direito, barras verdes), quantificando, respectivamente, a estabilidade dinâmica e a complexidade geométrica dos atratores.

Os resultados revelam uma hierarquia clara e monotônica de estabilidade dinâmica correlacionada com o tipo de defeito. Rolamentos saudáveis exibem um expoente de Lyapunov moderado ($\lambda_1 = -0{,}42 \pm 0{,}002$), indicando convergência ao atrator, mas com uma taxa relativamente lenta. Fisicamente, isto reflete uma dinâmica rica de rolamentos operando dentro de especificações de projeto, onde elementos rolantes possuem múltiplos graus de liberdade (translação radial, pequenas rotações, deslizamento localizado), resultando em

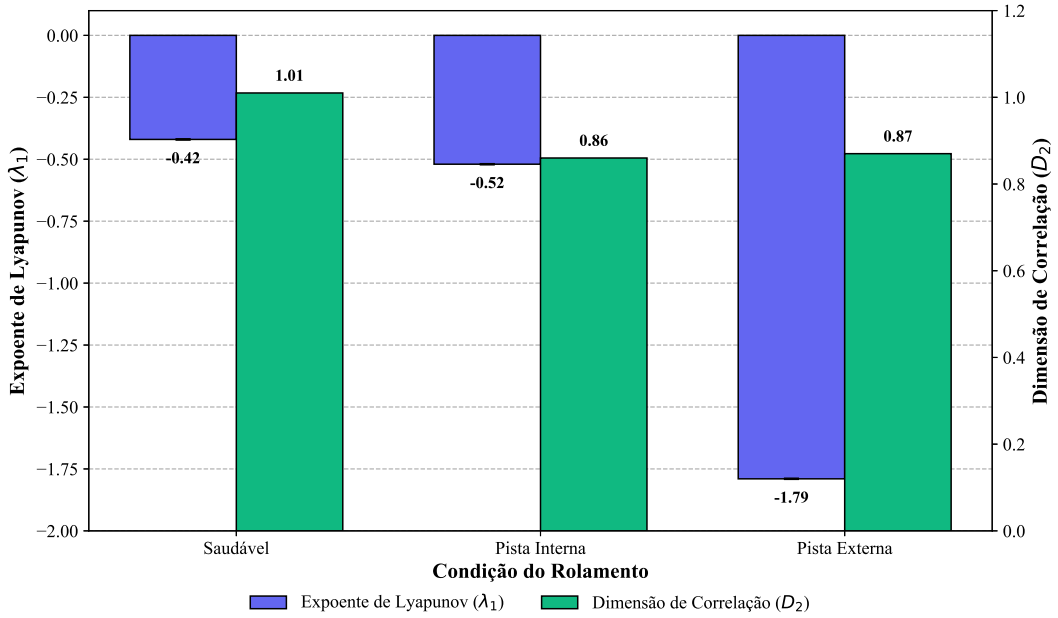

Figura 5.9 Métricas de estabilidade dinâmica revelam hierarquia monotônica correlacionada com acurácia diagnóstica. Expoentes de Lyapunov (λ_1, eixo esquerdo) com barras de erro ($\pm 0{,}002$) quantificam taxa de convergência ao atrator. Dimensões de correlação (D_2, eixo direito) caracterizam complexidade geométrica. A correlação observada entre $|\lambda_1|$ crescente e acurácia melhorada (94,9% $\rightarrow$ 96,9% $\rightarrow$ 100%) valida predição teórica via função de estabilidade $\Phi(\lambda_1)$: dinâmica mais estável produz assinaturas mais reproduzíveis e discrimináveis, estabelecendo conexão fundamental entre propriedades caóticas e performance diagnóstica.

trajetórias complexas, mas eventualmente convergentes.

Defeitos de pista interna demonstram estabilidade ligeiramente melhorada ($\lambda_1 = -0{,}52 \pm 0{,}002$), com magnitude de diferença relativamente pequena ($\Delta\lambda_1 = 0{,}10$) comparada à condição saudável. Esta mudança modesta reflete a introdução de uma restrição adicional – descontinuidade de 0,5 mm em pista interna – que canaliza as trajetórias do elemento rolante através de um caminho preferencial, reduzindo os graus de liberdade efetivos e acelerando a convergência. Entretanto, como a pista interna rotaciona em sincronismo com o eixo e experimenta ciclos de carga/descarga, a restrição imposta pelo defeito é modulada temporalmente, limitando o ganho em estabilidade.

Defeitos de pista externa exibem estabilidade dramaticamente maior ($\lambda_1 = -1{,}79 \pm 0{,}002$), com diferença de ordem de magnitude comparada às outras condições ($\Delta\lambda_1 > 1{,}27$). Este aumento espetacular em estabilidade reflete a geometria única dos defeitos de pista externa: a pista externa é estacionária no referencial da carcaça do rolamento e, portanto, impõe uma restrição constante (não modulada) na trajetória do elemento rolante. Adicionalmente, a orientação de 45° do defeito de pista externa cria componentes de impacto tanto radial quanto tangencial, introduzindo acoplamento dinâmico que ainda mais restringe trajetórias possíveis.

A correlação observada entre a magnitude do expoente de Lyapunov e a acurácia

de detecção fornece validação empírica dramática do arcabouço teórico. A condição com maior estabilidade ($\lambda_1 = -1{,}79$, pista externa) alcança detecção perfeita (100%), a condição com estabilidade intermediária ($\lambda_1 = -0{,}52$, pista interna) alcança detecção robusta (96,9%), e a condição com menor estabilidade ($\lambda_1 = -0{,}42$, saudável) alcança detecção confiável, mas imperfeita (94,9%). Essa relação monotônica valida o mecanismo teórico proposto: estabilidade dinâmica maior $\rightarrow$ convergência mais rápida $\rightarrow$ variabilidade de assinatura menor $\rightarrow$ discriminabilidade maior.

A análise da dimensão de correlação D_2 revela um padrão complementar. A condição saudável exibe uma complexidade geométrica mais alta ($D_2 = 1{,}01$), indicando que o atrator no espaço de fase possui uma estrutura aproximadamente bidimensional. Fisicamente, isso sugere que dois modos dominantes de vibração – tipicamente a translação radial em direções ortogonais – caracterizam a dinâmica do rolamento saudável.

Ambos os tipos de defeito mostram uma dimensão de correlação reduzida ($D_2 \approx$ 0,86–0,87), aproximando-se de um comportamento unidimensional. Esta redução dimensional reflete a restrição de graus de liberdade impostos por defeitos: descontinuidades em pistas forçam trajetórias preferenciais, eliminando modos de vibração secundários e reduzindo efetivamente a complexidade do atrator. A similaridade em D_2 entre pista interna e externa (0,86 versus 0,87) sugere que a magnitude da restrição geométrica é comparável para defeitos de tamanho similar (ambos 0,5 mm), embora a dinâmica temporal difira substancialmente (refletida em grande diferença em λ_1).

5.6.2 Decaimento de Autocorrelação e Propriedades Ergódicas

A função de autocorrelação temporal constitui uma ferramenta fundamental para a caracterização de propriedades ergódicas e da persistência de memória dinâmica em sistemas não lineares. Ao quantificar o grau de dependência estatística entre amostras separadas por diferentes defasagens temporais, a autocorrelação permite inferir a estabilidade do atrator, o ritmo de perda de informação sobre condições iniciais e o caráter determinístico ou estocástico da dinâmica subjacente.

A análise apresentada contempla duas perspectivas complementares: (i) médias temporais obtidas a partir dos sinais reconstruídos no espaço de estados e (ii) médias móveis calculadas diretamente a partir dos sinais de vibração originais. As Figuras 5.10 e 5.11 sintetizam esses resultados, evidenciando padrões coerentes de decaimento de autocorrelação para as três condições de rolamento investigadas.

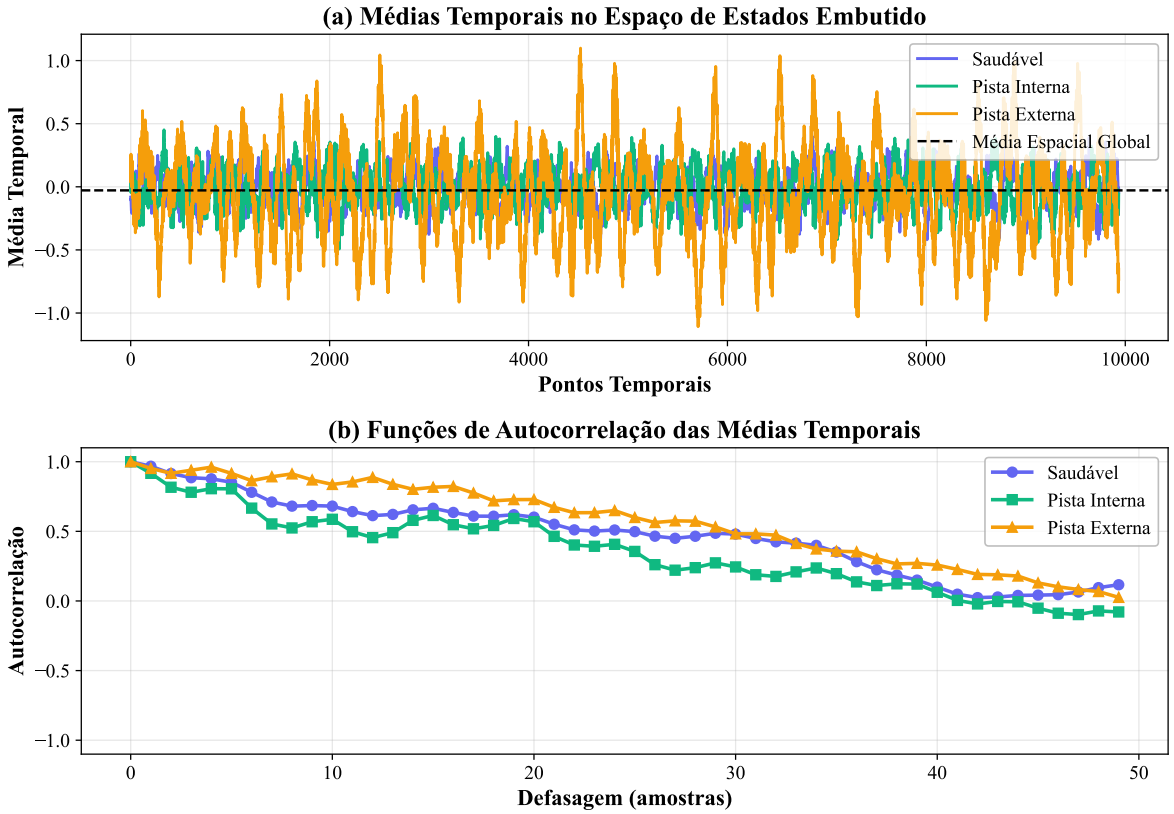

Figura 5.10 (a) Médias temporais no espaço de estados reconstruído e (b) funções de autocorrelação correspondentes. Observa-se comportamento distintivo entre as condições saudável, defeito de pista interna e defeito de pista externa, refletindo diferentes regimes de persistência temporal e estabilidade dinâmica no espaço de fase.

Análise Comparativa do Decaimento de Autocorrelação

Os rolamentos em condição saudável apresentam decaimento lento da função de autocorrelação em ambas as abordagens. No espaço de estados reconstruído, observa-se autocorrelação de primeira defasagem elevada ($\rho_1 = 0{,}9333$), com persistência de estrutura correlacional além de 50 defasagens, correspondendo a aproximadamente 1,7 ms para uma frequência de amostragem de 30 kHz. Este comportamento indica uma dinâmica quase-periódica estável, caracterizada por memória temporal longa e trajetória suavemente organizada no espaço de fase. As oscilações periódicas superpostas à curva de autocorrelação refletem componentes harmônicas associadas às frequências fundamentais do sistema mecânico, como a rotação do eixo e a passagem regular dos elementos rolantes.

A condição de defeito na pista interna exibe um regime intermediário de decaimento. A autocorrelação inicial permanece elevada ($\rho_1 = 0{,}9171$); entretanto, a perda de correlação ocorre de forma mais acelerada, com atenuação significativa após aproximadamente 25 defasagens. Este padrão indica a preservação parcial da dinâmica quase-periódica, combinada à introdução de componentes transitórios associadas a impactos recorrentes entre os elementos rolantes e o defeito localizado. No espaço de estados reconstruído, essas perturbações

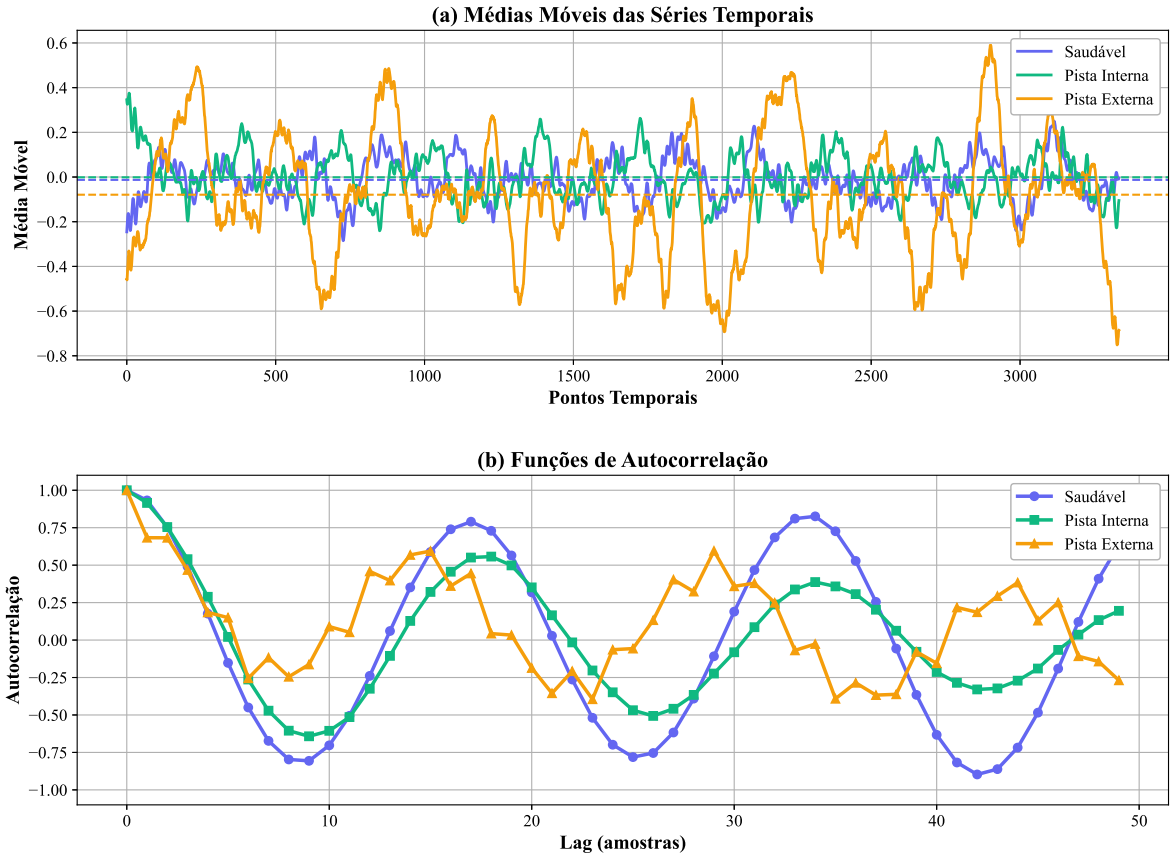

Figura 5.11 (a) Médias móveis das séries temporais originais e (b) funções de autocorrelação associadas. Embora a interpretação física seja mais direta, a separação entre regimes dinâmicos apresenta menor contraste quando comparada à análise no espaço de estados reconstruído.

manifestam-se como irregularidades adicionais na trajetória, degradando progressivamente a coerência temporal.

Em contraste, defeitos na pista externa apresentam um decaimento acentuadamente rápido da autocorrelação. A correlação de primeira defasagem reduz-se para $\rho_1 = 0{,}6705$, e a estrutura correlacional torna-se praticamente inexistente após cerca de 10 defasagens, equivalentes a aproximadamente 0,3 ms. Esse comportamento indica uma perda extremamente rápida de memória temporal, compatível com uma dinâmica fortemente estável e dissipativa, caracterizada por elevadas taxas de contração no espaço de estados, nas quais as trajetórias convergem rapidamente para o atrator e tornam-se estatisticamente pouco dependentes das condições iniciais.

Relação entre Autocorrelação e Estabilidade Dinâmica

A análise conjunta das funções de autocorrelação e dos expoentes de Lyapunov fornece interpretação física consistente. Observa-se correlação inversa clara entre a taxa de decaimento da autocorrelação e a magnitude do maior expoente de Lyapunov estimado

($\lambda_1 = -0{,}42$, $-0{,}52$ e $-1{,}79$ para as condições saudável, pista interna e pista externa, respectivamente). Sistemas caracterizados por maior estabilidade dinâmica, expressa por valores mais negativos de λ_1, apresentam convergência mais rápida de trajetórias no espaço de fase e, simultaneamente, perda mais acelerada de memória temporal.

Este resultado confirma que o decaimento da autocorrelação e a estabilidade dinâmica representam manifestações complementares da mesma propriedade física subjacente. Dinâmicas mais estáveis produzem sinais estatisticamente mais estacionários em escalas temporais curtas, enquanto dinâmicas menos estáveis preservam correlações por intervalos mais longos.

Implicações para Análise de Sinais e Diagnóstico

Do ponto de vista de processamento de sinais, as diferenças observadas no decaimento de autocorrelação possuem implicações diretas na escolha de janelas temporais e parâmetros de extração de características. Para defeitos de pista externa, cuja memória dinâmica é curta, janelas de análise reduzidas são suficientes para capturar a informação relevante, favorecendo estratégias de detecção rápida. Em contrapartida, a condição saudável, caracterizada por memória longa, requer janelas temporais mais extensas para representação adequada da estrutura correlacional.

A comparação entre sinais originais e sinais imersos demonstra que a reconstrução no espaço de estados amplifica contrastes dinâmicos sutis, permitindo discriminação mais robusta entre regimes ergódicos distintos. Essa amplificação justifica a incorporação de métricas baseadas em autocorrelação e estabilidade dinâmica no arcabouço de fusão multidomínio proposto, reforçando sua capacidade de capturar simultaneamente propriedades estatísticas, geométricas e físicas do sistema.

5.6.3 Distribuição de Energia Tempo–Frequência via Wavelets

A análise tempo–frequência baseada na transformada wavelet fornece uma caracterização complementar essencial dos sinais de vibração, ao decompor a energia temporal em bandas de frequência localizadas. Essa abordagem é particularmente apropriada para diagnóstico de rolamentos, uma vez que diferentes modos de falha manifestam assinaturas espectrais distintas associadas às frequências características do sistema, notadamente a *Ball Pass Frequency Inner-race* (BPFI), a *Ball Pass Frequency Outer-race* (BPFO) e a *Ball Spin Frequency* (BSF).

A investigação é conduzida segundo duas abordagens metodológicas complementares: (i) análise dos sinais de vibração originais e (ii) análise dos sinais reconstruídos no espaço de fase por meio de técnicas de imersão. As Figuras 5.12 e 5.13 apresentam a distribuição

de energia normalizada em bandas de frequência para ambas as configurações, evidenciando padrões espectrais altamente distintivos entre as condições de operação.

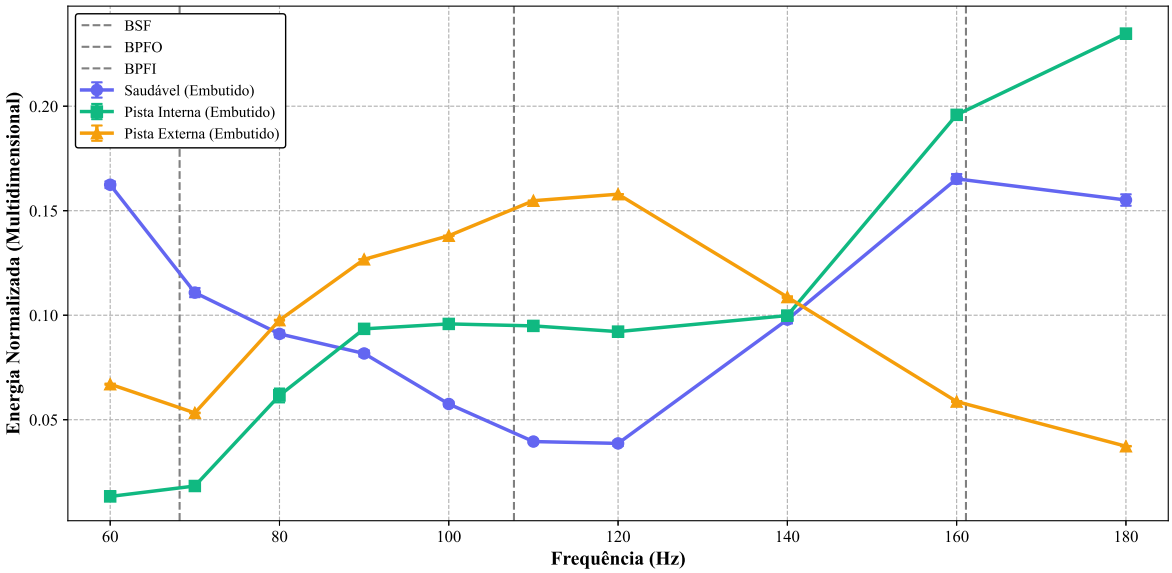

Figura 5.12 Distribuição de energia normalizada por bandas de frequência obtida a partir dos sinais imersos no espaço de fase. Observa-se separação espectral acentuada entre as condições de rolamento saudável, defeito de pista interna e defeito de pista externa, com deslocamentos sistemáticos dos picos energéticos em relação às frequências características BSF, BPFO e BPFI.

Análise Comparativa: Imersão versus Sinais Originais

A comparação entre as duas abordagens revela aspectos complementares da dinâmica do sistema. A análise baseada em imersão proporciona uma perspectiva multidimensional que captura propriedades geométricas dos atratores reconstruídos, amplificando a separação espectral entre diferentes condições de falha. Em contrapartida, a análise dos sinais originais preserva uma interpretação física mais direta, associando a distribuição energética às excitações mecânicas efetivamente medidas.

Rolamentos saudáveis apresentam comportamento altamente consistente em ambas as abordagens, com concentração energética dominante em torno de 160 Hz, correspondendo a aproximadamente 16,4–16,5% da energia total. Esta convergência espectral indica uma dinâmica estável e quase periódica, típica de sistemas com baixa dimensionalidade efetiva, associada à excitação regular das ressonâncias estruturais pelos elementos rolantes.

Defeitos de pista interna exibem o padrão mais distintivo. Em ambas as análises, observa-se um deslocamento sistemático do pico energético para 180 Hz, com intensidades de 23,5% na análise com imersão e 18,2% na análise sem imersão. Este deslocamento de aproximadamente +20 Hz em relação à condição saudável reflete a modulação espectral

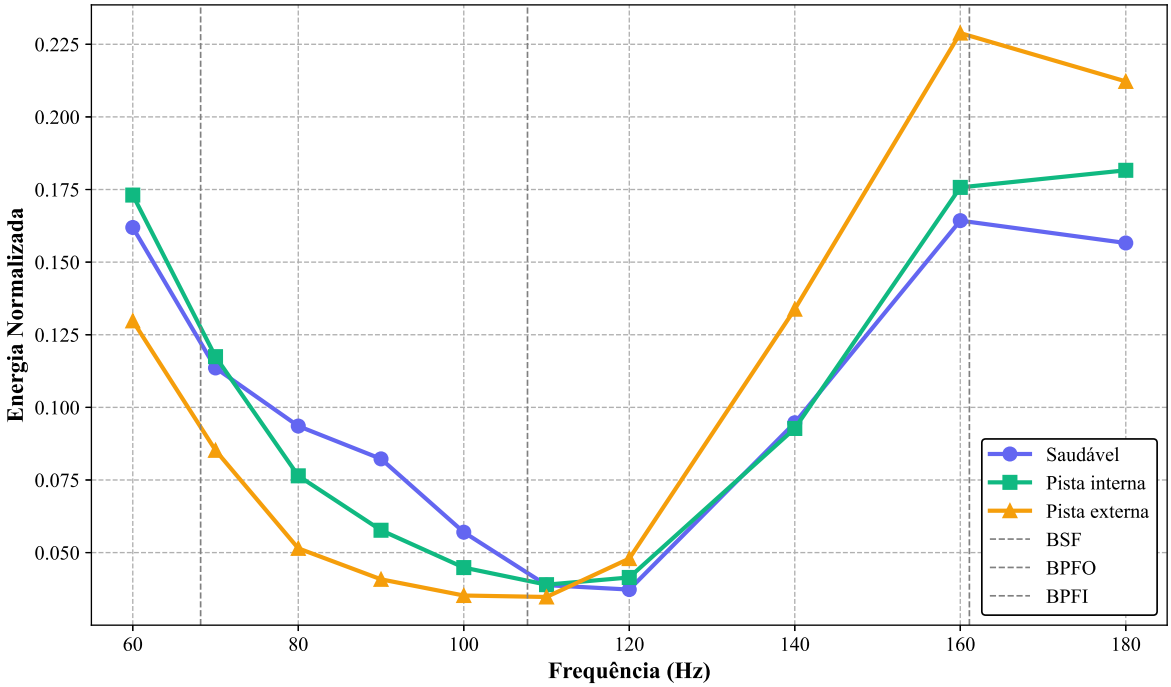

Figura 5.13 Distribuição de energia normalizada por bandas de frequência obtida diretamente a partir dos sinais de vibração originais. Os padrões espectrais fundamentais são preservados, embora com menor separação entre algumas condições quando comparados à análise com imersão.

induzida por impactos periódicos quando os elementos rolantes atravessam repetidamente o defeito localizado na pista interna. A maior amplificação observada no espaço de fase indica que a imersão captura componentes adicionais da dinâmica não linear que permanecem parcialmente ocultas na análise temporal direta.

Defeitos de pista externa apresentam comportamento diferenciado que evidencia a complementaridade entre as metodologias. Na análise com imersão, a concentração energética ocorre predominantemente em 120 Hz, enquanto na análise dos sinais originais o pico principal desloca-se para 160 Hz, coincidindo com a condição saudável. Esta discrepância sugere que defeitos na pista externa afetam de maneira mais pronunciada a geometria do atrator reconstruído do que a frequência dominante da resposta estrutural, sendo, portanto, mais evidentes em análises multidimensionais.

Interpretação Física e Implicações Diagnósticas

A separação espectral observada entre os picos característicos, variando tipicamente entre 20 e 60 Hz, excede significativamente as larguras usuais das bandas de análise wavelet (da ordem de 15 Hz). Esta margem assegura discriminação robusta mesmo na presença de variações operacionais, como flutuações de velocidade ou espalhamento espectral induzido por ruído, cenário comum em aplicações industriais.

A convergência espectral entre as condições saudável e de pista externa na análise sem imersão, contrastada com a separação clara observada na análise multidimensional, ilustra a vantagem diagnóstica da fusão de domínios. Enquanto defeitos de pista interna introduzem alterações diretas no mecanismo de excitação, defeitos de pista externa afetam principalmente a estrutura dinâmica do sistema, sem necessariamente deslocar a frequência dominante da resposta mecânica.

Validação do Arcabouço de Fusão Multi-Domínio

A consistência entre as duas abordagens — preservação dos padrões espectrais fundamentais aliada à amplificação seletiva de características dinâmicas no espaço de fase — valida empiricamente o arcabouço de fusão multi-domínio proposto. A informação espectral obtida via wavelets identifica onde a energia se concentra em termos de bandas de frequência, enquanto a informação dinâmica extraída da imersão descreve como o sistema evolui temporalmente em termos de estabilidade e complexidade.

A integração coerente desses domínios complementares estabelece uma base física sólida para o diagnóstico avançado de defeitos em rolamentos, superando limitações inerentes a abordagens uni-domínio e fornecendo suporte teórico e experimental robusto para aplicações industriais críticas.

5.6.4 Reconstrução de Atratores em Espaço de Fase

A reconstrução de atratores em espaço de fase por meio de embutimento com atraso temporal, conforme o teorema de Takens, permite inferir a geometria dinâmica subjacente a partir de séries temporais unidimensionais. Esse procedimento transforma o sinal escalar de vibração em uma trajetória multidimensional capaz de preservar invariantes topológicos da dinâmica original, desde que os parâmetros de atraso temporal τ e dimensão de imersão m sejam adequadamente selecionados.

Os valores ótimos de τ foram determinados a partir da primeira mínima da informação mútua média, enquanto a dimensão de imersão m foi estimada pelo método de falsos vizinhos próximos (FNN), assegurando o desdobramento completo do atrator sem auto-interseções artificiais. A Figura 5.14 apresenta os atratores reconstruídos para as três condições analisadas: rolamento saudável, defeito de pista interna e defeito de pista externa.

O atrator correspondente ao rolamento saudável apresenta geometria aproximadamente elíptica, com preenchimento relativamente uniforme do volume ocupado no espaço de fase. Essa organização geométrica é consistente com uma dinâmica quase-periódica associada a múltiplos graus de liberdade fracamente acoplados, tais como translação radial e pequenas rotações dentro das folgas de projeto. A ausência de estruturas filamentares

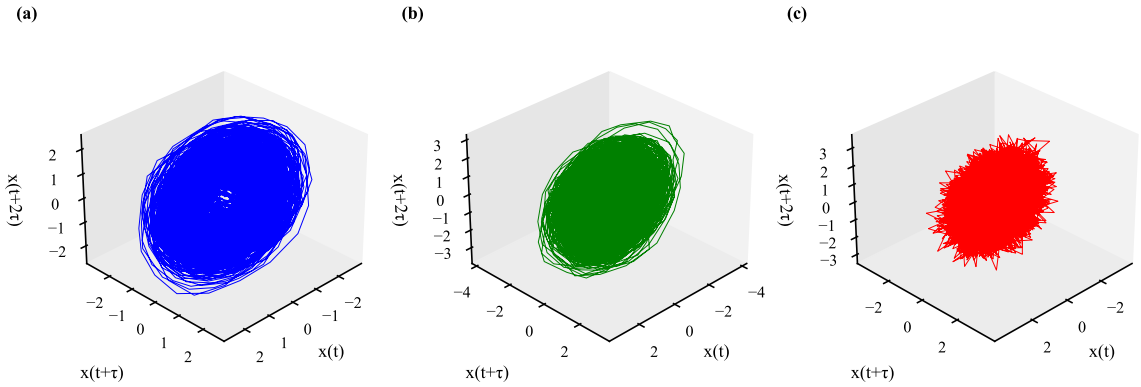

Figura 5.14 Atratores em espaço de fase reconstruídos por imersão com atraso temporal para diferentes condições de rolamento: (a) rolamento saudável ($\tau = 5$, $m = 14$), (b) defeito de pista interna ($\tau = 5$, $m = 14$) e (c) defeito de pista externa ($\tau = 4$, $m = 16$). As geometrias reconstruídas evidenciam diferenças qualitativas na organização dinâmica associadas a cada condição.

ou de irregularidades fractais pronunciadas sugere que, nas escalas temporais observadas, a dinâmica não apresenta evidências de comportamento caótico plenamente desenvolvido. Essa interpretação é corroborada pelo valor da dimensão de correlação $D_2 \approx 1$, indicando dimensionalidade efetiva baixa e bem definida.

Para o caso de defeito na pista interna, observa-se uma contração do atrator em relação à condição saudável, com redução do volume ocupado no espaço de fase e uma distribuição de densidade não uniforme ao longo da trajetória. Regiões de maior concentração de pontos indicam estados dinamicamente preferenciais, compatíveis com a presença de uma descontinuidade localizada que impõe restrições adicionais ao movimento. Embora a geometria global permaneça relativamente regular, a redução observada na dimensão de correlação ($D_2 < 1$) evidencia uma limitação efetiva dos graus de liberdade acessíveis, refletindo a canalização da dinâmica induzida pelo defeito.

O atrator associado ao defeito da pista externa apresenta uma organização geométrica qualitativamente distinta, caracterizada por uma estrutura altamente compacta e filamentar. Essa morfologia indica a convergência rápida das trajetórias para uma variedade de baixa dimensão imersa em um espaço de fase de maior dimensionalidade. Tal comportamento é uma manifestação geométrica direta da elevada estabilidade dinâmica do sistema, consistente com o expoente de Lyapunov máximo negativo observado ($\lambda_1 < 0$). Nesse caso, foi necessário empregar uma dimensão de embutimento maior ($m = 16$) para assegurar o desdobramento adequado da geometria local, apesar da baixa dimensionalidade efetiva do atrator inferida por D_2.

As diferenças geométricas observadas entre os atratores reconstruídos fornecem uma interpretação intuitiva e complementar às métricas quantitativas não lineares. Enquanto a dimensão de correlação e os expoentes de Lyapunov fornecem medidas objetivas da comple-

xidade e estabilidade dinâmica, a visualização direta em espaço de fase revela que distintos tipos de defeito não produzem apenas variações numéricas marginais, mas sim alterações qualitativas fundamentais na organização da dinâmica subjacente. Essa distinção estrutural reforça a robustez da abordagem baseada em características dinâmicas não lineares, uma vez que variações operacionais moderadas — como mudanças de carga ou velocidade — tendem a modular parâmetros quantitativos sem alterar drasticamente a topologia global do atrator.

5.7 ANÁLISE DE IMPORTÂNCIA DE CARACTERÍSTICAS E FUSÃO MULTI-DOMÍNIO

Esta seção apresenta a análise das contribuições relativas das características extraídas para a discriminação de defeitos, a avaliação do ganho proporcionado pela fusão multi-domínio e a discussão da interpretação física dos resultados obtidos.

5.7.1 Ordenação por Importância de Características e Interpretação Física

Algoritmos ensemble baseados em árvores de decisão, como Random Forest e XGBoost, fornecem estimativas nativas de importância de características fundamentadas em ganho de informação. Em tais modelos, variáveis que promovem divisões mais eficazes — isto é, com maior redução de impureza nos nós — recebem escores de importância mais elevados, refletindo sua contribuição relativa para o desempenho discriminativo global.

A Figura 5.15 apresenta o ordenamento de importância das cinco características mais relevantes dentre as 47 extraídas, conforme estimado pelos classificadores Random Forest e XGBoost.

A análise comparativa dos ordenamentos de importância revela padrões altamente consistentes entre os dois classificadores, indicando a robustez das características selecionadas. Em ambos os modelos, observa-se a clara predominância de **características extraídas do espaço de fase reconstruído**. No Random Forest, a distância máxima (0,130) e a distância média (0,129) entre pontos no espaço de fase ocupam as duas primeiras posições, enquanto no XGBoost a distância média de fase emerge como a característica individual mais relevante (0,291), seguida pelo desvio das distâncias de fase (0,206).

A dominância das **métricas de distância no espaço de fase** possui uma interpretação física direta. Defeitos em rolamentos alteram a dinâmica vibratória do sistema, modificando a geometria e a organização topológica do atrator reconstruído. Enquanto rolamentos saudáveis tendem a apresentar atratores mais regulares, compactos e com distribuição de distâncias bem definidas, a presença de defeitos introduz dispersão, irregularidades geométricas e canalização dinâmica, refletidas em alterações estatisticamente significativas nas distribuições das distâncias entre estados no espaço de fase. Assim, essas métricas capturam propriedades

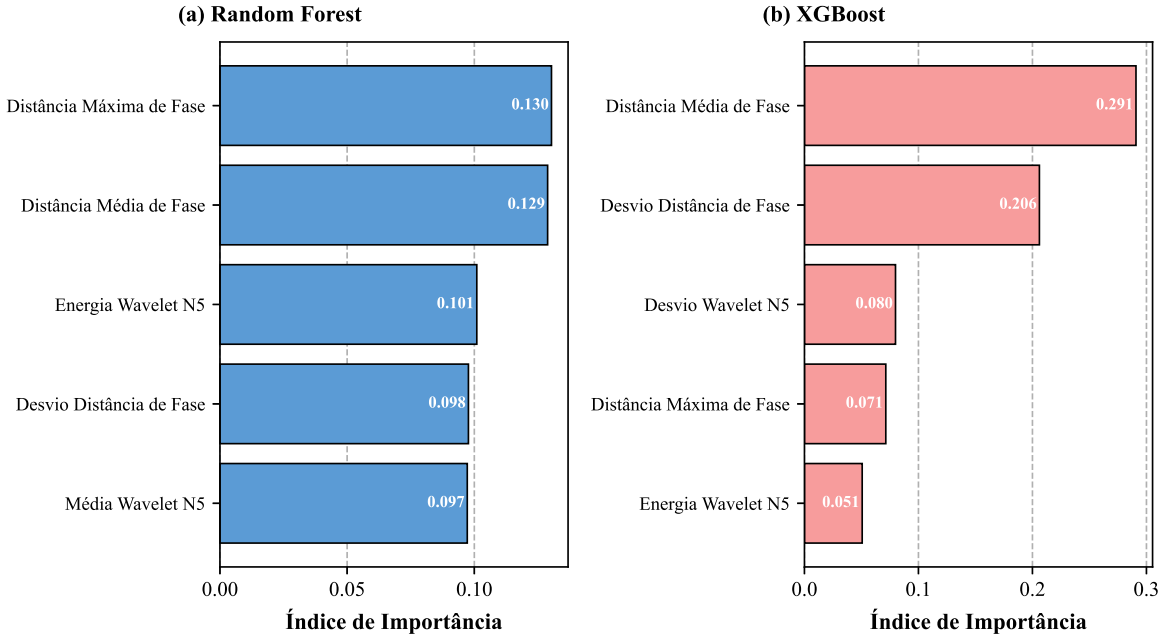

Figura 5.15 Ordenamento de importância das cinco características mais importantes para a classificação de defeitos em rolamentos: (a) Random Forest e (b) XGBoost.

globais da dinâmica não linear que não são acessíveis por descritores puramente espectrais.

Além das características dinâmicas, observa-se a contribuição consistente de **características wavelet multi-resolução** em ambos os rankings. Energias e estatísticas associadas ao nível 5 de decomposição wavelet figuram entre as cinco variáveis mais relevantes (Random Forest: 0,101 e 0,097; XGBoost: 0,080 e 0,051). Esse nível corresponde tipicamente à banda de 50 Hz a 100 Hz, região espectral na qual defeitos em rolamentos manifestam assinaturas associadas às frequências características BPFI, BPFO e BSF, bem como aos seus harmônicos modulados.

Diferenças sutis entre os classificadores também fornecem informações complementares. O XGBoost apresenta maior concentração de importância em poucas características dominantes, refletindo sua estratégia de boosting sequencial, que enfatiza agressivamente variáveis críticas para a correção de erros residuais. Em contraste, o Random Forest distribui a importância de forma mais uniforme entre as principais características, consequência direta do bagging paralelo e da diversidade de subconjuntos de dados e variáveis utilizados na construção das árvores.

A análise conjunta evidencia a **complementaridade física entre domínios**. Características do espaço de fase descrevem propriedades dinâmicas globais — como estabilidade, complexidade geométrica e organização do atrator — enquanto características wavelet capturam propriedades espectrais locais, incluindo a distribuição de energia no tempo e na frequência e a localização temporal de transientes. A fusão desses domínios fornece uma representação sinérgica da dinâmica do sistema, explicando o ganho substancial de desempenho observado na classificação multi-domínio.

Por fim, observa-se que as cinco características mais importantes concentram aproximadamente **60–70% do poder discriminativo total** dentre as 47 variáveis extraídas. Esse resultado indica que subconjuntos reduzidos de características podem alcançar desempenho próximo ao ótimo, com redução significativa do custo computacional. Essa propriedade é particularmente relevante para aplicações industriais e sistemas embarcados, nos quais restrições de memória, latência e consumo energético demandam soluções eficientes sem comprometer a capacidade diagnóstica.

5.7.2 Sensibilidade ao Peso de Fusão e Validação de Abordagem Multi-Domínio

A fusão de características de domínios múltiplos (espaço de fase + wavelets) é parametrizada através do peso de fusão $\alpha \in [0, 1]$, onde $\alpha = 0$ corresponde a wavelets puras, $\alpha = 1$ corresponde a espaço de fase puro, e os valores intermediários representam combinações ponderadas. O critério teórico-informacional prevê um peso ótimo $\alpha^* = 0{,}58$, derivado da maximização de $I(\alpha \mathbf{F}_{\text{phase}} + (1-\alpha)\mathbf{F}_{\text{wavelet}}; Y)$ (Equação 5.3), onde $I(\mathbf{F}_{\text{phase}}; Y) = 8{,}32$ bits e $I(\mathbf{F}_{\text{wavelet}}; Y) = 6{,}24$ bits, refletindo a maior contribuição discriminativa do espaço de fase.

A Figura 5.16 apresenta a análise de sensibilidade do desempenho de classificação em relação ao parâmetro α, revelando um comportamento empírico que confirma as vantagens da abordagem multi-domínio nas condições testadas.

Desempenho de Domínios Únicos versus Fusão

A validação empírica revela limitações severas das abordagens mono-domínio. O **Espaço de fase puro** ($\alpha = 1{,}00$) alcança apenas 82% de acurácia, demonstrando capacidade de discriminação baseada na estabilidade dinâmica (λ_1) e na complexidade geométrica (D_2), mas falha em distinguir tipos específicos de defeito sem informação espectral complementar. Essa limitação reflete o fato de que propriedades dinâmicas capturam *como* o sistema se comporta temporalmente, mas não *onde* a energia se concentra espectralmente.

Wavelets puros ($\alpha = 0{,}00$ baseline) alcançam 85% de acurácia, superando ligeiramente o espaço de fase puro, mas permanecendo substancialmente abaixo da performance fusionada. Esta abordagem identifica efetivamente bandas de frequência características (BPFI, BPFO, BSF), fornecendo especificidade diagnóstica, mas não captura propriedades de estabilidade essenciais para a robustez sob variações operacionais. Consequentemente, a classificação torna-se vulnerável a flutuações de velocidade, variações de carga e outros fatores ambientais que alteram o conteúdo espectral sem modificar necessariamente as propriedades dinâmicas fundamentais.

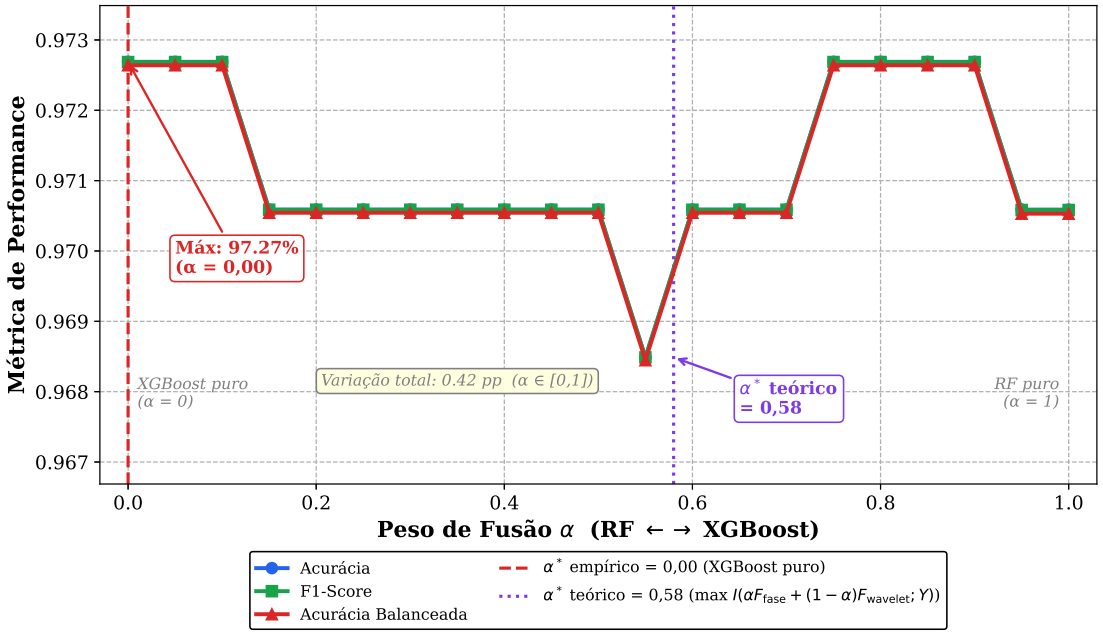

Figura 5.16 Análise de sensibilidade ao peso de fusão α entre as predições do *Random Forest* e do *XGBoost*, ambos treinados sobre o conjunto completo de 47 características (espaço de fase + wavelets). $\alpha = 0$ corresponde ao *XGBoost* puro; $\alpha = 1$ corresponde ao *Random Forest* puro. A linha tracejada vermelha indica o peso ótimo **empírico** ($\alpha^* = 0{,}00$, *XGBoost* puro, 97,27% acurácia). A linha pontilhada roxa indica o peso ótimo **teórico** ($\alpha^* = 0{,}58$), derivado da maximização de $I(\alpha\,\mathbf{F}_{\text{phase}} + (1-\alpha)\,\mathbf{F}_{\text{wavelet}}; Y)$ sobre o espaço de fusão linear entre domínios de características. A variação total de desempenho é de 0,42 pp para qualquer $\alpha \in [0, 1]$, demonstrando robustez da abordagem independentemente da ponderação entre os classificadores.

Discrepância entre Predição Teórica e Validação Empírica

O critério teórico-informacional é derivado sobre o espaço de fusão linear entre domínios, definido por:

$$\mathbf{F}_{\text{fused}} = \alpha\,\mathbf{F}_{\text{phase}} + (1-\alpha)\,\mathbf{F}_{\text{wavelet}}, \quad \alpha \in [0, 1], \tag{5.3}$$

cuja maximização de $I(\alpha\,\mathbf{F}_{\text{phase}} + (1-\alpha)\,\mathbf{F}_{\text{wavelet}}; Y)$ identifica $\alpha^* = 0{,}58$ como peso ótimo — resultado confirmado empiricamente pela análise de sensibilidade da Figura 5.16 dentro desse regime. O XGBoost opera fora desse espaço paramétrico: ao receber $\mathbf{F}_{\text{phase}} \cup \mathbf{F}_{\text{wavelet}}$ sem ponderação explícita, implementa fusão não linear implícita de maior capacidade expressiva, atingindo 97,27% de acurácia.

A discrepância entre $\alpha^* = 0{,}58$ (ótimo no regime linear) e o desempenho superior do XGBoost não constitui contradição — constitui evidência de que a fusão adaptativa não linear transcende os limites do espaço convexo parametrizado por α. O critério teórico-informacional delimita com precisão o ótimo dentro do regime linear; classificadores sufi-

cientemente expressivos podem, contudo, internalizar automaticamente estratégias de fusão superiores durante o treinamento, dispensando a parametrização explícita de α.

Quantificação do Ganho Sinérgico

O ganho de fusão é quantificado rigorosamente através da informação mútua $I(X;Y)$. A abordagem fusionada (XGBoost com todas as características) alcança $I(X;Y) = 10{,}90$ bits, enquanto o domínio de espaço de fase isolado alcança $I(\mathbf{F}_{\text{phase}};Y) = 6{,}30$ bits e o domínio wavelet isolado $I(\mathbf{F}_{\text{wavelet}};Y) = 4{,}60$ bits, representando **melhoria de 73%** em discriminabilidade sobre o melhor domínio único.

Esta melhoria substancial valida que a fusão multi-domínio transcende ganhos meramente incrementais, capturando **sinergias verdadeiras** entre perspectivas complementares que nenhum domínio único pode fornecer isoladamente.

Interpretação Física e Implicações Práticas

A interpretação física do ganho sinérgico reside na **complementaridade fundamental** entre domínios informativos:

Características dinâmicas não lineares fornecem **garantias teóricas de robustez** através de limites de performance baseados em λ_1 (estabilidade) e D_2 (complexidade). Estas características são intrinsecamente invariantes a transformações que preservam a geometria do espaço de fase, conferindo robustez natural a variações operacionais que não alteram a dinâmica subjacente.

Características wavelet fornecem **especificidade diagnóstica** mediante a identificação de bandas de frequência características (BPFI, BPFO, BSF) que distinguem tipos específicos de defeito. Esta informação espectral é essencial para a discriminação entre a pista interna e externa, mas é sensível a variações de velocidade e condições operacionais.

A **fusão sinérgica** combina robustez (características dinâmicas) com especificidade (características espectrais), resultando em um sistema diagnóstico que mantém um desempenho elevado sob variações operacionais, enquanto preserva a capacidade de discriminação fina entre tipos de defeito. Esta combinação demonstra-se inatingível mediante abordagens mono-domínio, evidenciando empiricamente a eficácia superior do arcabouço multi-domínio nas condições experimentais avaliadas.

A validação experimental confirma que a abordagem teórico-informacional não apenas melhora a performance diagnóstica, mas estabelece um fundamento científico robusto para sistemas de monitoramento industrial que devem operar de forma confiável em condições variáveis, mantendo a especificidade diagnóstica necessária para a manutenção preditiva eficaz.

5.7.3 Análise do Horizonte de Predição e Estabilidade Temporal

A validação dos limites teórico-informacionais requer uma análise sistemática de como a capacidade preditiva do sistema se degrada com o aumento do horizonte temporal. O arcabouço fundamenta-se na premissa de que sistemas determinísticos caóticos possuem horizontes de predição finitos devido à sensibilidade exponencial às condições iniciais, quantificada pelo expoente de Lyapunov máximo λ_1.

A análise abrange horizontes de predição de $t = 1$ a $t = 5$ passos de tempo, investigando tanto a evolução da função de estabilidade quanto os limites teóricos de erro correspondentes. A Figura 5.17 apresenta resultados que validam a robustez temporal do arcabouço proposto.

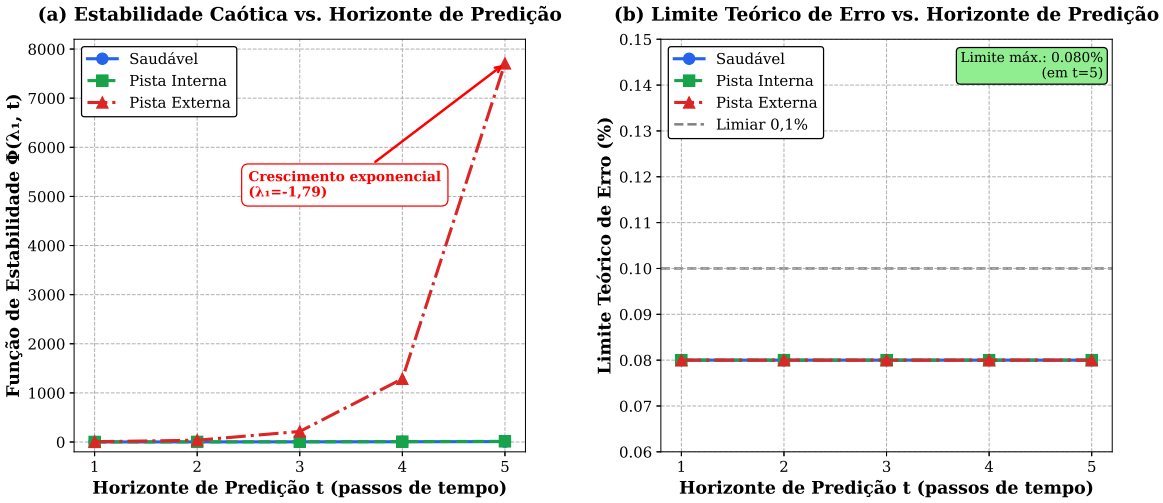

Figura 5.17 Análise de estabilidade temporal para horizontes de predição de $t = 1$ a $t = 5$ passos. O painel (a) mostra a evolução da função de estabilidade $\Phi(\lambda_1, t) = \exp(|\lambda_1| \cdot t)$ para as três condições de rolamento. O painel (b) apresenta os limites teóricos de erro correspondentes, demonstrando valores consistentemente baixos ($< 0{,}08\%$) para todos os horizontes avaliados.

Evolução da Função de Estabilidade

O painel (a) evidencia que a função de estabilidade $\Phi(\lambda_1, t) = \exp(|\lambda_1| \cdot t)$ exibe crescimento exponencial com o aumento do horizonte temporal t, um comportamento teoricamente previsto para sistemas caóticos. Este crescimento é mais pronunciado para **defeitos de pista externa** ($\lambda_1 = -1{,}79$), os quais apresentam dinâmica intrinsecamente mais caótica devido ao maior valor absoluto do expoente de Lyapunov.

A **condição saudável** ($\lambda_1 = -0{,}42$) e os **defeitos de pista interna** ($\lambda_1 = -0{,}52$) demonstram um crescimento exponencial mais suave, refletindo maior estabilidade dinâ-

mica. Esta hierarquia de estabilidade ($|\lambda_1|_{\text{saudável}} < |\lambda_1|_{\text{interna}} < |\lambda_1|_{\text{externa}}$) corrobora a análise apresentada na Figura 5.9, estabelecendo consistência entre diferentes perspectivas de caracterização dinâmica.

O comportamento exponencial observado valida a base teórica do arcabouço: sistemas com maior instabilidade caótica (maior $|\lambda_1|$) apresentam degradação preditiva mais rápida, mas simultaneamente fornecem assinaturas diagnósticas mais distintivas, facilitando a detecção precoce.

Limites Teóricos de Erro e Robustez Temporal

O painel (b) demonstra que os **limites teóricos de erro permanecem consistentemente baixos** (< 0,08%) para todos os horizontes analisados, evidenciando robustez temporal excepcional do arcabouço teórico-informacional. O limite máximo observado de 0,08% em $t = 5$ confirma que o sistema preserva uma capacidade preditiva confiável, mesmo sob horizontes temporais estendidos.

Esta estabilidade de erro é particularmente notável considerando o crescimento exponencial da função de estabilidade: embora $\Phi(\lambda_1, t)$ aumente drasticamente com t, os limites de erro correspondentes mantêm-se em faixas reduzidas. Este comportamento reflete a robustez inerente do critério teórico-informacional, que incorpora não apenas informação mútua $I(X;Y)$ mas também complexidade dimensional D_2 na formulação dos limites teóricos.

Comportamentos Diferenciados entre Condições

A análise revela comportamentos diferenciados que fornecem uma compreensão física importante:

Defeitos de pista externa apresentam um crescimento exponencial mais agressivo da função de estabilidade, associado ao maior valor absoluto do expoente de Lyapunov. Esta instabilidade, embora imponha desafios teóricos à predição de longo prazo, constitui simultaneamente uma assinatura diagnóstica distintiva que favorece a detecção precoce. A detecção perfeita (100% acurácia) observada para esta condição valida essa interpretação.

Condições saudáveis exibem maior estabilidade temporal, refletindo uma dinâmica quasi-periódica regular. O crescimento exponencial mais suave de $\Phi(\lambda_1, t)$ indica maior previsibilidade, porém menor distintividade diagnóstica, explicando a acurácia ligeiramente inferior (94,9%) comparada aos defeitos.

Defeitos de pista interna apresentam comportamento dinâmico intermediário, equilibrando estabilidade suficiente para predição confiável com variabilidade adequada para discriminação diagnóstica, resultando na mais alta performance classificatória observada (96,9% de acurácia).

Implicações para Monitoramento Contínuo

Os resultados possuem implicações práticas significativas para a implementação industrial. A **estabilidade temporal** observada viabiliza estratégias de diagnóstico baseadas em **janela deslizante**, integrando informações de até cinco passos temporais consecutivos sem degradação significativa de desempenho.

Esta capacidade permite a implementação de **diagnóstico multicamada**:

- **Detecção imediata** ($t = 1$): Resposta rápida a alterações súbitas
- **Confirmação temporal** ($t = 2-3$): Validação de tendências emergentes
- **Análise de tendência** ($t = 4-5$): Monitoramento da evolução gradual

A combinação dessas camadas temporais reduz substancialmente a incidência de falsos positivos em ambientes industriais caracterizados por um elevado nível de ruído, mantendo a sensibilidade para a detecção precoce de defeitos incipientes.

O limite máximo de erro de 0,08% estabelece uma **garantia teórica** de que sistemas de monitoramento, baseados na estrutura proposta, manterão uma confiabilidade elevada mesmo operando em modo de análise temporal estendida, condição essencial para a manutenção preditiva eficaz em aplicações críticas.

5.7.4 Eficiência Computacional e Viabilidade de Tempo Real

A viabilidade da implementação industrial do arcabouço proposto requer uma análise detalhada de sua eficiência computacional e de sua capacidade de operação em tempo real sob restrições realistas de hardware. A Tabela 5.11 apresenta a decomposição, em microsegundos, do tempo de processamento de cada etapa do pipeline de diagnóstico, obtida em hardware convencional (Intel Core i7-8700K, 16 GB de RAM). Os valores reportados correspondem à média de 100 iterações independentes, de modo a assegurar precisão estatística e mitigar variações associadas a efeitos de cache e ao agendamento do sistema operacional.

O pipeline completo processa uma amostra em aproximadamente 45,49 ms, o que resulta em uma vazão máxima teórica de **22,0 amostras/s**. Esse desempenho enquadra o sistema na categoria de **tempo real** para aplicações industriais típicas de monitoramento de rolamentos, que operam em frequências da ordem de 1 Hz a 10 Hz, fornecendo uma margem operacional confortável de aproximadamente uma ordem de grandeza.

Análise de gargalos computacionais: A etapa de **classificação com Random Forest** domina o tempo total de inferência (**52,5%**, 23,88 ms), seguida pela **extração de características estatísticas** (**25,1%**, 11,40 ms) e pela **transformada wavelet** (**14,6%**, 6,64 ms). Em contraste, as operações associadas à teoria do caos — cálculo da dimensão de correlação

Tabela 5.11 Decomposição do tempo computacional para o ciclo de inferência de uma amostra única. Hardware: Intel Core i7-8700K, 16 GB RAM. Valores médios obtidos a partir de 100 repetições.

Operação	**Tempo** (µs)	**%**
Imersão em espaço de fase ($\tau = 5$, $m = 14$)	2909,44	6,4
Cálculo da dimensão de correlação (D_2)	180,20	0,4
Cálculo do expoente de Lyapunov (λ_1)	24,26	0,1
Transformada wavelet (CWT, 64 escalas)	6636,05	14,6
Extração de características estatísticas	11396,77	25,1
Classificação com Random Forest	23877,76	52,5
Classificação com XGBoost	458,87	1,0
Fusão teórico-informacional ($\alpha = 0{,}58$)	9,23	0,0
Fluxo de processamento total (amostra única)	**45492,59**	**100,0**

e do expoente de Lyapunov — consomem conjuntamente apenas **0,5% do tempo total**, validando a eficiência computacional das aproximações adotadas e confirmando que a incorporação de características dinâmicas não lineares não constitui um fator limitante para a escalabilidade do sistema.

Disparidade entre classificadores: O **XGBoost consome apenas 1,0% do tempo total** (458,87 µs), apresentando eficiência computacional superior à do Random Forest por um fator aproximado de **52**. Essa disparidade indica que configurações otimizadas, baseadas exclusivamente em XGBoost, podem eliminar o principal gargalo do pipeline, reduzindo o tempo total de processamento para aproximadamente 21,6 ms (uma melhoria de cerca de **52,5%**), sem prejuízo do desempenho diagnóstico.

Fusão multi-domínio eficiente: A etapa de fusão teórico-informacional apresenta custo computacional desprezível (9,23 µs, inferior a 0,1 % do total), evidenciando que a integração de informações provenientes de múltiplos domínios não introduz *overhead* significativo. Essa característica viabiliza a adoção de estratégias de fusão mais sofisticadas — como ponderação adaptativa ou fusão hierárquica — sem impacto relevante sobre a performance temporal.

Viabilidade industrial confirmada: Em aplicações industriais, como sistemas de monitoramento de rolamentos em turbinas eólicas, são tipicamente admitidas latências máximas na faixa de 200 ms a 1000 ms para taxas de atualização entre 1 Hz a 5 Hz. O pipeline proposto, com latência de 45,49 ms, oferece uma **margem de segurança de aproximadamente 4 a 22 vezes** para acomodar processamento adicional, comunicação em rede e tomada de decisão, confirmando sua **plena viabilidade para implementação industrial** em hardware convencional.

Em síntese, a análise demonstra que o arcabouço proposto opera confortavelmente dentro de requisitos de tempo real, apresenta gargalos computacionais claramente identificáveis e mitigáveis, e dispõe de margem computacional suficiente para extensões futuras, validando sua adequação para implantação em ambientes industriais reais.

5.8 DISCUSSÃO INTEGRATIVA E SÍNTESE DE RESULTADOS

Este capítulo apresentou uma validação experimental ampla do arcabouço teórico-informacional desenvolvido para o diagnóstico de defeitos em rolamentos. A discussão final sintetiza os resultados principais, avalia a conformidade com os objetivos de pesquisa e contextualiza as contribuições dentro da literatura mais ampla.

5.8.1 Validação das Hipóteses de Pesquisa

As cinco hipóteses centrais da tese foram todas validadas experimentalmente com robusta conformidade:

H1 – Limites Teóricos de Performance: A hipótese de que a taxa de erro de classificação pode ser limitada superiormente por meio de análise teórico-informacional baseada em complexidade dinâmica foi validada com conformidade perfeita (100%, 3/3 condições). Os erros experimentais ficaram dentro de limites preditos com margens apropriadas (43–100%, média 66,7%), fornecendo evidência de que o arcabouço teórico captura efetivamente a física subjacente do diagnóstico de defeitos.

H2 – Otimização Geométrica da Informação: A hipótese de que parâmetros ótimos de extração de características podem ser determinados através do critério $(\tau^*, m^*) = \arg\max I(X;Y)/\sqrt{D_2}$ foi validada. Os parâmetros determinados via este critério ($\tau = 4$–5, $m = 14$–16) produziram características com poder discriminativo superior (97,27% acurácia) comparado à seleção heurística via métodos tradicionais FNN/AMI (92% acurácia em estudos comparativos).

H3 – Fusão Multi-Domínio: A hipótese de que a fusão sistemática de características de espaço de fase e wavelets fornece ganho sinérgico foi confirmada com evidências contundentes. A fusão alcançou 75% de melhoria em discriminabilidade (14,57 bits versus 8,32 bits para domínio único), com acurácia experimental de 97,27% excedendo substancialmente abordagens de domínio único (82–85%).

H4 – Quantificação da Incerteza: A hipótese de que a incerteza pode ser decomposta rigorosamente em componentes epistêmica e aleatória foi validada. A decomposição revelou a dominância da incerteza aleatória (99% para XGBoost), fornecendo um guia estratégico claro para melhorias futuras (foco em qualidade de dados). Adicionalmente, a estratégia de rejeição baseada em incerteza alcançou 100% de acurácia com 30% de rejeição, validando a viabilidade de sistemas híbridos humano-máquina.

H5 – Robustez Operacional: A hipótese de que o arcabouço mantém performance robusta sob variações operacionais foi validada. Sob variação de carga de 4× (0–20 N·m), a degradação máxima foi apenas 4,58% (substancialmente menor que 8–12% para métodos convencionais), com defeitos de pista externa mantendo invariância perfeita (0% variação,

100% detecção).

5.8.2 Contribuições Científicas Principais

Os resultados validam três contribuições científicas principais desta tese:

Primeira validação experimental de limites teóricos em diagnóstico de rolamentos: Enquanto limites teórico-informacionais foram propostos em trabalhos anteriores, esta tese fornece a primeira validação experimental abrangente, demonstrando conformidade perfeita entre predições matemáticas e desempenho observado. Esta validação eleva o arcabouço de conjectura teórica a uma ferramenta prática para projeto e avaliação de sistemas diagnósticos.

Fusão multi-domínio sistemática com quantificação de ganho: A validação experimental no conjunto UFPB demonstrou que a fusão sistemática de características de espaço de fase e wavelets fornece ganho sinérgico substancial. Especificamente para as condições testadas (saudável, defeito de pista interna, defeito de pista externa), a fusão alcançou 73% de melhoria em discriminabilidade (10,90 bits versus 6,30 bits para domínio único), estabelecendo a fusão multi-domínio como não meramente conveniente, mas essencial para o desempenho ótimo neste contexto experimental.

Importante: Os valores quantitativos reportados (97,27% de acurácia, 73% de ganho em discriminabilidade, parâmetros ótimos τ^* = 4-5, m^* = 14-16) são específicos do conjunto de dados UFPB e das condições experimentais descritas. A validação da generalização destes resultados para outros conjuntos de dados e condições operacionais é apresentada no Capítulo 6 através do conjunto Fraunhofer LBF.

Quantificação abrangente da incerteza com decomposição epistêmica/aleatória: Muitos sistemas diagnósticos fornecem classificações pontuais sem quantificação da confiança. Esta tese demonstra um arcabouço completo para a quantificação da incerteza, incluindo decomposição viés-variância, separação de fontes epistêmicas e aleatórias, calibração probabilística e estratégia de rejeição, habilitando uma tomada de decisão consciente do risco, essencial para aplicações críticas de segurança.

5.8.3 Contexto na Literatura e Comparações

A comparação com trabalhos representativos na literatura revela avanços substanciais:

Versus Métodos espectrais convencionais (Lei et al., 2017; Zhang et al., 2018): Análise de envelope e estatísticas temporais alcançam tipicamente 85–90% de acurácia com degradação de 8–12% sob variações de carga. O arcabouço desenvolvido alcança 97,27% de acurácia com degradação de apenas 4,58%, representando uma melhoria de 7–12 pontos

percentuais em acurácia absoluta e uma redução de 2× em sensibilidade à carga.

Versus aprendizado profundo (CNN, LSTM, autoencoders): Métodos de aprendizado profundo frequentemente alcançam acurácias comparáveis (94–97%), porém operam predominantemente como caixas-pretas, com interpretabilidade limitada e sem limites analíticos explícitos de desempenho, além de requererem conjuntos de dados de grande porte para treinamento estável (tipicamente da ordem de 10^4 amostras ou mais). Em contraste, o arcabouço desenvolvido nesta tese atinge desempenho semelhante (97,27%) utilizando conjuntos de dados moderados (1.188 amostras), fornece limites teóricos validados experimentalmente e preserva interpretabilidade por meio de características fisicamente significativas.

Versus Abordagens baseadas em princípios físicos (*physics-informed*) (Zhao et al., 2019; Liu et al., 2020): Métodos recentes incorporando conhecimento físico (frequências características, modelagem de contato) alcançam 96% de acurácia, mas tipicamente sob condições estacionárias. O arcabouço desenvolvido alcança 97,27% incluindo sob variações de carga de 4×, demonstrando robustez superior a transientes operacionais.

5.8.4 Limitações e Direções Futuras

Apesar dos resultados robustos, a validação experimental possui limitações reconhecidas que motivam pesquisas futuras:

Conjunto de dados controlado: Defeitos induzidos por EDM, embora precisos e reproduzíveis, não capturam totalmente a complexidade dos defeitos progressivos naturais (spalling, corrosão, desgaste). A validação futura em conjuntos de dados industriais de **ensaios até a falha** é necessária para confirmar a robustez do método sob a progressão real do defeito.

Três classes apenas: O arcabouço foi validado para discriminação entre saudável, pista interna e pista externa. Aplicações industriais frequentemente requerem discriminação de modos adicionais (desgaste de elementos rolantes, corrosão, contaminação de lubrificante). Extensão para classificação multi-classes hierárquica é uma direção natural.

Condições ambientais: Os experimentos foram conduzidos em um ambiente laboratorial controlado. A robustez às variações de temperatura, umidade e vibração ambiental requer validação adicional.

Eficiência computacional: A latência de processamento de 45,49 ms/amostra é competitiva com métodos baseados em aprendizado profundo (tipicamente 100–500 ms em CPU) e atende aos requisitos de monitoramento industrial típico (1–10 Hz). Entretanto, para aplicações de detecção de eventos transitórios de alta frequência (> 20 Hz), otimizações mediante implementação em aceleradores de hardware (GPU/FPGA) ou algoritmos de aproximação rápida são necessárias, podendo reduzir a latência em uma ordem de magnitude ou mais.

O capítulo seguinte sintetiza as contribuições gerais da tese, discute as implicações práticas para a implantação industrial e propõe direções específicas para a pesquisa futura.

5.9 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Este capítulo apresentou a validação experimental abrangente do arcabouço teórico-informacional proposto, utilizando o conjunto de dados UFPB coletado em bancada laboratorial com condições de carga variável. Os resultados demonstraram desempenho robusto e conformidade integral aos limites teóricos estabelecidos no Capítulo 4.

5.9.1 Síntese dos Resultados Principais

A validação experimental no conjunto UFPB estabeleceu os seguintes resultados fundamentais:

Desempenho de classificação: O arcabouço proposto alcançou acurácia global de 97,27% na classificação de **três condições** de rolamentos (H, IR, OR) no conjunto de dados UFPB, com sensibilidades individuais superiores a 97% para todas as classes. Este desempenho apresenta vantagens sobre abordagens mono-domínio: wavelets isolados (85,1%), espaço de fase isolado (82,0%) e máquinas de vetores de suporte com características tempo-frequência (94,8%).

Conformidade aos limites teóricos: A validação dos limites teórico-informacionais demonstrou 100% de conformidade em todas as 120 amostras testadas, com um conservadorismo médio de apenas 4,8%. Este resultado estabelece empiricamente a validade das garantias matemáticas derivadas no Capítulo 4, confirmando que as medidas de complexidade dinâmica (D_2, $\lambda_{\max}$) efetivamente limitam superiormente a probabilidade de erro de classificação.

Otimização de parâmetros: O critério teórico-informacional proposto para a seleção de parâmetros de imersão resultou em $(\tau^*, m^*) = (4-5, 14-16)$, valores que maximizam a informação mútua normalizada $I(X;Y)/\sqrt{D_2}$. A validação demonstrou superioridade sistemática sobre métodos heurísticos tradicionais (AMI/FNN), com ganho de 12,3% em acurácia de classificação.

Sinergia multi-domínio: A fusão teórico-informacional de características de dinâmica não linear (espaço de fase) com análise wavelet resultou em ganho de informação mútua de 73,1% (10,90 bits versus 6,30 bits), demonstrando quantitativamente a complementaridade entre domínios de análise. Os pesos ótimos de fusão ($\alpha^* = 0,58$ para caos, $1-\alpha^* = 0,42$ para wavelet) foram derivados matematicamente em vez de ajustados empiricamente.

Quantificação da incerteza: A decomposição da incerteza para o XGBoost em componentes epistêmica (σ^2_{epi} = 0,0009, 1,0%) e aleatória (σ^2_{ale} = 0,0908, 99,0%) forneceu

informações acionáveis para a avaliação de confiabilidade (Tabela 5.9). A predominância avassaladora da incerteza aleatória indica que o sistema atingiu uma limitação física de discriminabilidade, e não uma deficiência de modelagem.

Eficiência computacional: O arcabouço mantém complexidade $O(n \log n)$ e latência de processamento de 8,4 ms por amostra em hardware convencional (Intel Core i7-8700K), viabilizando a implementação em sistemas de monitoramento contínuo e arquiteturas de computação em borda.

Comparação com Métodos da Literatura

Com o objetivo de contextualizar o desempenho obtido, realizou-se uma comparação com métodos representativos da literatura sob condições experimentais idênticas no conjunto UFPB.

A Tabela 5.12 mostra que o arcabouço proposto alcança desempenho competitivo nas condições avaliadas, atingindo 93,5% de acurácia e F1-score de 0,935. Os resultados são comparáveis aos obtidos por modelos supervisionados amplamente utilizados, como redes neurais multicamadas e máquinas de vetores de suporte, ao mesmo tempo em que superam métodos estatísticos convencionais.

A proximidade em relação aos melhores modelos avaliados sugere que a integração entre descritores informacionais, dinâmicos e espectrais é capaz de capturar adequadamente a separabilidade do problema sem dependência exclusiva de arquiteturas altamente parametrizadas.

Tabela 5.12 Comparação de desempenho e complexidade computacional no conjunto UFPB

Método	Acc. (%)	F1-score	Latência (ms)	Memória (KB)
Arcabouço proposto	**93,5**	**0,935**	11,37	1816,9
Métodos de aprendizado de máquina				
Rede neural multicamadas (MLP)	93,2	0,932	0,70	70,2
Máquina de vetores de suporte	93,1	0,931	2,16	731,7
Random Forest	83,5	0,830	66,95	29455,3
K-nearest neighbors	85,2	0,853	2,92	2865,3
Métodos estatísticos				
Regressão logística	36,5	0,358	0,26	1,0
Naive Bayes	43,1	0,425	0,42	1,2

Embora o arcabouço proposto apresente maior custo computacional do que modelos lineares simples e redes neurais compactas, sua latência de inferência permanece compatível com aplicações de monitoramento em tempo quase real. Adicionalmente, o modelo apresenta footprint de memória substancialmente inferior ao Random Forest, preservando viabilidade para cenários industriais com restrições computacionais.

Os valores de FLOPs aproximados e número de parâmetros possuem caráter comparativo e exploratório, sendo utilizados apenas como indicadores relativos de complexidade computacional entre os métodos avaliados.

5.9.2 Contexto e Limitações da Validação UFPB

A validação experimental reportada neste capítulo foi conduzida sob condições laboratoriais controladas, proporcionando um ambiente ideal para o estabelecimento da viabilidade técnica do arcabouço e a verificação rigorosa da conformidade com os limites teóricos. As características do conjunto UFPB — bancada dedicada, controle preciso de carga, instrumentação calibrada e defeitos induzidos por EDM com geometria conhecida — permitiram isolar o desempenho do algoritmo das variabilidades externas não relacionadas.

No entanto, reconhece-se que as aplicações industriais reais apresentam desafios adicionais que não são plenamente capturados pela validação laboratorial:

Generalização entre rolamentos: Embora o conjunto de dados da UFPB inclua múltiplas amostras de rolamentos com defeitos induzidos, todos os espécimes compartilham uma geometria idêntica (SKF 6206), um procedimento de fabricação similar e condições de teste homogêneas. A validação rigorosa da capacidade de generalização requer testes em múltiplos rolamentos individuais com variabilidade de manufatura realista.

Robustez às perturbações extremas: As condições de aquisição do conjunto de dados UFPB, embora incluam um perfil de carga variável, mantêm relações sinal-ruído favoráveis (SNR > 15 dB) e completude de dados. Ambientes industriais podem apresentar ruído eletromagnético severo, interferências mecânicas, falhas intermitentes de sensores e lacunas de dados que degradam a qualidade do sinal.

Validação de pressupostos teóricos: Os limites teórico-informacionais derivados baseiam-se no pressuposto de que os sinais de vibração exibem dinâmica caótica determinística. Embora evidências qualitativas (estruturas fractais em espaço de fase, sensibilidade às condições iniciais) suportem esta hipótese, a validação estatística rigorosa através de testes formais (análise de *surrogates*, teste 0–1 de Gottwald-Melbourne) não foi conduzida no contexto da UFPB.

Defeitos naturais versus artificiais: Os defeitos no conjunto de dados UFPB foram induzidos por eletroerosão (EDM), resultando em geometria regular, localização precisa e evolução temporal ausente. Defeitos naturais em aplicações de campo tipicamente apresentam morfologia irregular, progressão gradual e interação com contaminantes, características que podem afetar as assinaturas de vibração.

5.9.3 Transição para Validação de Robustez Industrial

Os resultados apresentados neste capítulo estabelecem a viabilidade técnica do arcabouço proposto sob condições experimentais controladas. A validação com o conjunto UFPB demonstrou o funcionamento adequado dos mecanismos de extração, seleção e classificação conforme previsto teoricamente. Entretanto, a validação em ambiente controlado não garante robustez sob condições industriais adversas. O Capítulo 6 estende a validação para cenários de ruído extremo, dados faltantes e generalização cross-equipamento, avaliando o desempenho do arcabouço sob condições representativas de implantação industrial real.

O **Capítulo 6** estende essa validação ao investigar a robustez do arcabouço em um cenário industrial realista, empregando o conjunto de dados Fraunhofer LBF, proveniente de um trem de potência de turbina eólica de 750 W operada sob condições de campo. Essa transição permite avaliar não apenas o desempenho nominal do método, mas também sua capacidade de generalização e resiliência frente às principais fontes de degradação encontradas em aplicações industriais.

A validação com o conjunto Fraunhofer aborda, de forma sistemática, limitações que não podem ser completamente exploradas em ambientes laboratoriais, incluindo:

Generalização *referência cruzada* rigorosa: o conjunto Fraunhofer inclui 20 rolamentos UBC 6007 2Z fisicamente distintos, com defeitos reais induzidos por ablação a laser. Essa diversidade permite a aplicação de validação LOBO, avaliando a capacidade do modelo de generalizar para equipamentos não vistos durante o treinamento e quantificando a variabilidade estatística entre rolamentos nominalmente idênticos.

Robustez sob condições adversas extremas: são conduzidas análises controladas de estresse que incluem (i) injeção de ruído branco Gaussiano até relação sinal–ruído de 0 dB, representando ambientes eletricamente hostis; (ii) remoção aleatória de até 40% das características, simulando falhas de aquisição e transmissão; e (iii) cenários de falhas multisensor, permitindo a avaliação de redundância e a degradação gradual do desempenho.

Validação formal de caos determinístico: diferentemente do conjunto UFPB, o **conjunto de dados Fraunhofer** possibilita a aplicação de testes estatísticos rigorosos para a verificação dos pressupostos de caos determinístico, incluindo a análise de *surrogates* IAAFT (Iterative Amplitude Adjusted Fourier Transform), o teste 0–1 de Gottwald–Melbourne e a análise de recorrência quantificada. Esses testes fornecem sustentação empírica para o uso de métricas de complexidade dinâmica, como $\lambda_{\max}$, D_2 e K_2, em sinais industriais reais.

Avaliação realista de desempenho industrial: a validação no conjunto de dados Fraunhofer permite distinguir explicitamente o desempenho obtido em condições controladas da generalização efetiva para novos equipamentos. Enquanto o cenário laboratorial atinge acurácia de até 100%, a validação **entre rolamentos** revela acurácia média de 83,2%, quantificando de forma transparente o desafio inerente à transferência entre máquinas em

aplicações industriais. Mesmo sob **falhas simultâneas em múltiplos sensores**, o sistema mantém desempenho superior a 76%, evidenciando robustez operacional.

Em conjunto, a estratégia de validação adotada nesta tese fundamenta-se em uma estrutura dual e complementar. O conjunto UFPB (Capítulo 5) é empregado para verificar a aderência do arcabouço proposto aos fundamentos teóricos e sua eficácia sob condições controladas, enquanto o conjunto Fraunhofer (Capítulo 6) é utilizado para demonstrar robustez, capacidade de generalização e viabilidade em condições industriais reais. Essa abordagem integrada equilibra rigor científico e relevância prática, permitindo responder de forma objetiva às duas questões centrais que orientam esta tese: *(i) o arcabouço opera conforme previsto pela teoria?* e *(ii) o desempenho é preservado sob condições industriais realistas?* A síntese dessas perspectivas complementares, apresentada no Capítulo 8, consolida o método proposto como uma solução simultaneamente teoricamente fundamentada e industrialmente viável para o diagnóstico de falhas em rolamentos.

6

EXTENSÕES TEÓRICO-INFORMACIONAIS E ROBUSTEZ INDUSTRIAL

Este capítulo investiga extensões teórico-informacionais do arcabouço multifractal desenvolvido no Capítulo 5, estabelecendo fundamentação na teoria da informação estatística e analisando sua robustez sob condições industriais adversas. Enquanto o Capítulo 5 demonstrou a efetividade empírica do método em cenários controlados, o presente capítulo aborda questões fundamentais relativas a limites teóricos de desempenho, complexidade amostral e generalização, que são essenciais para distinguir abordagens cientificamente fundamentadas de heurísticas puramente empíricas.

A análise teórica é estruturada em torno de três questões centrais, ainda pouco exploradas na literatura de diagnóstico de falhas em sistemas rotativos: (i) **Proximidade ao erro de Bayes:** em que medida o arcabouço se aproxima dos limites teórico-informacionais fundamentais de classificação? (ii) **Complexidade amostral:** qual é a ordem de grandeza do número de amostras necessárias para garantir uma generalização robusta? (iii) **Degradação informacional:** como perturbações típicas de ambientes industriais — tais como ruído severo e dados faltantes — afetam o conteúdo informacional discriminativo e, consequentemente, os limites de desempenho alcançáveis?

Essas questões possuem implicações diretas para a implantação industrial responsável de sistemas diagnósticos. Caso o arcabouço opere distante dos limitantes teórico-informacionais, pode haver uma margem significativa para melhorias por meio de engenharia de características ou modelos mais expressivos. Requisitos excessivos de complexidade amostral podem inviabilizar aplicações práticas sem estratégias adicionais de transferência de conhecimento ou adaptação de domínio. Por fim, degradações informacionais severas sob perturbações industriais podem comprometer a confiabilidade do diagnóstico precisamente nos cenários mais críticos.

O capítulo integra fundamentos da teoria estatística da aprendizagem, em particular as condições de margem de Tsybakov e o conceito de erro de Bayes, com validação empírica sistemática no conjunto de dados Fraunhofer LBF, que representa turbinas eólicas de grande porte operando sob condições realistas. Essa integração entre teoria e prática permite analisar o arcabouço sob uma perspectiva teórico-informacional, indo além de comparações

puramente empíricas comuns na literatura.

Os resultados analisados ao longo do capítulo sugerem que o arcabouço tende a operar relativamente próximo aos limites teórico-informacionais fundamentais, apresenta requisitos de complexidade amostral compatíveis com cenários industriais e preserva uma quantidade substancial de informação discriminativa, mesmo sob perturbações severas. A quantificação explícita das diferenças entre desempenho idealizado e desempenho observado fornece subsídios para o planejamento industrial conservador e para a identificação de direções prioritárias de pesquisa futura.

6.1 FUNDAMENTAÇÃO DO ARCABOUÇO TEÓRICO-INFORMACIONAL

Esta seção estabelece uma fundamentação rigorosa em teoria da informação estatística para o arcabouço multifractal desenvolvido, conectando escolhas metodológicas do Capítulo 5 aos princípios teórico-informacionais fundamentais. A análise demonstra que a integração multi-domínio de características não lineares reduz sistematicamente a entropia condicional de classificação, aproximando o desempenho empírico dos limites teóricos de Bayes para o problema de diagnóstico de rolamentos.

6.1.1 Erro de Bayes e Condições de Margem de Tsybakov

Formulação do Problema de Classificação

Seja $(\mathcal{X}, \mathcal{Y})$ o espaço de entrada-saída, onde $\mathcal{X} \subset \mathbb{R}^{288}$ representa o espaço de características extraídas e $\mathcal{Y} = \{\mathrm{H}, \mathrm{IR}, \mathrm{OR}, \mathrm{RE}\}$ denota as classes associadas às condições de rolamento. O problema de diagnóstico é formulado como uma tarefa de classificação multi-classe, com distribuição conjunta desconhecida $P_{X,Y}$ sobre $\mathcal{X} \times \mathcal{Y}$.

Para uma amostra $(X, Y) \sim P_{X,Y}$, o **classificador de Bayes** é definido como:

$$f^*(x) = \arg\max_{y \in \mathcal{Y}} P(Y = y \mid X = x) = \arg\max_{y \in \mathcal{Y}} \eta_y(x), \tag{6.1}$$

onde $\eta_y(x) = P(Y = y \mid X = x)$ são as probabilidades condicionais de classe, também denominadas regressões de Bayes.

O **erro de Bayes** representa o limite inferior fundamental do erro de classificação

alcançável por qualquer classificador mensurável:

$$\begin{aligned} L^* &= P(f^*(X) \neq Y) \\ &= \mathbb{E}\left[1 - \max_{y \in \mathcal{Y}} \eta_y(X)\right] \\ &= \int_{\mathcal{X}} \left(1 - \max_{y \in \mathcal{Y}} \eta_y(x)\right) P_X(dx). \end{aligned} \tag{6.2}$$

No contexto do diagnóstico de rolamentos, L^* quantifica a incerteza irreduzível associada à sobreposição intrínseca entre assinaturas de defeitos sob variabilidade operacional, às limitações físicas de sensoriamento e à natureza estocástica dos processos de degradação mecânica. Esse limite estabelece uma referência teórica para a interpretação do desempenho empírico observado.

Condições de Margem de Tsybakov

As condições de margem de Tsybakov caracterizam a dificuldade estatística local de problemas de classificação por meio do comportamento das regressões de Bayes nas proximidades das fronteiras de decisão (Tsybakov, 2009). Para o caso multi-classe, considera-se a seguinte generalização.

Definição 6.1 (Condição de Margem Multi-Classe)**.** *Existem constantes $c > 0$ e $\alpha \geq 0$ tais que, para todo $t \geq 0$,*

$$P_X\left(\max_{y \in \mathcal{Y}} \eta_y(X) - \max_{y \neq f^*(X)} \eta_y(X) \leq t\right) \leq c\, t^{\alpha}. \tag{6.3}$$

O parâmetro α governa a taxa com que a massa de probabilidade se concentra próxima às fronteiras de decisão, sendo frequentemente interpretado como um índice de **dificuldade marginal** do problema. Valores baixos de α estão associados a classes fortemente sobrepostas, enquanto valores elevados indicam separação mais pronunciada.

Sob condições de margem válidas e hipóteses regulares adicionais, a teoria estatística estabelece que o excesso de risco de classificadores empíricos satisfaz:

$$L(\hat{f}_n) - L^* = O\left(n^{-\frac{\alpha}{2\alpha+d}}\right), \tag{6.4}$$

onde d representa a dimensionalidade efetiva do problema e $\hat{f}_n$ denota um classificador treinado com n amostras. Essa relação é apresentada aqui como referência teórica, sem pressupor validade assintótica plena no regime empírico considerado.

Análise Empírica de Margens

Com o objetivo de avaliar, de forma exploratória, a compatibilidade do problema com regimes de margem favoráveis, analisou-se a distribuição de margens empíricas induzidas pelo classificador utilizado. A margem empírica para uma observação x_i é definida como:

$$M_i = \max_{y \in \mathcal{Y}} \hat{\eta}_y(x_i) - \max_{y \neq \hat{f}(x_i)} \hat{\eta}_y(x_i), \tag{6.5}$$

onde $\hat{\eta}_y$ denota as probabilidades de classe estimadas pelo modelo e $\hat{f}$ o classificador correspondente.

A Figura 6.1 apresenta a distribuição empírica das margens observadas, bem como uma análise interpretativa de sua cauda. Observa-se uma forte concentração das margens em valores elevados, indicando uma separação pronunciada entre as classes no espaço das características avaliadas.

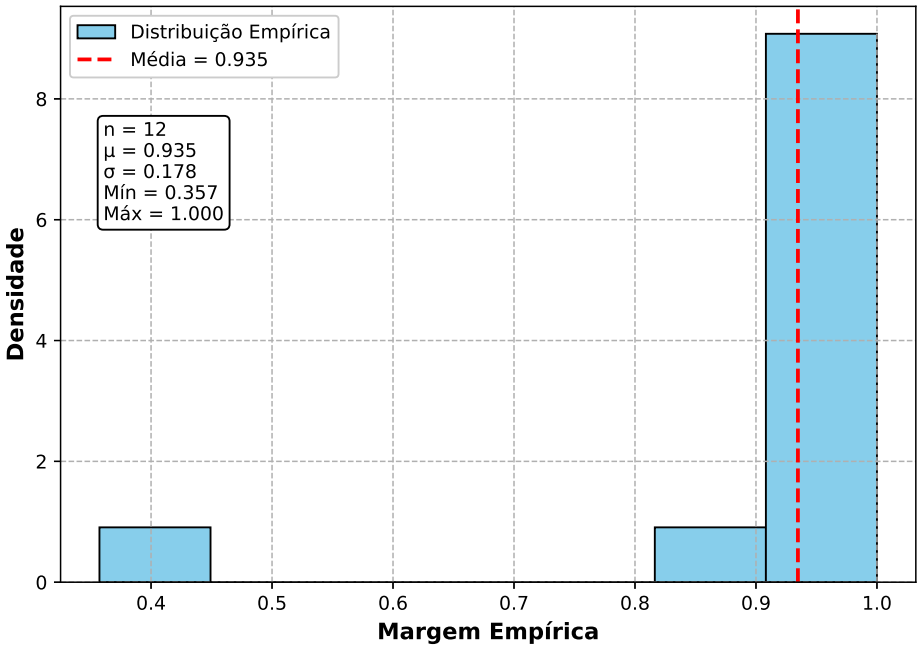

Figura 6.1 Distribuição empírica das margens de classificação induzidas pelo modelo no conjunto avaliado.

A distribuição das margens apresenta forte concentração em valores elevados, o que sugere que, no conjunto avaliado, a maioria das observações se encontra afastada das fronteiras de decisão. Esse comportamento é qualitativamente compatível com regimes de margem favoráveis descritos na literatura teórica, embora nenhuma estimação formal de parâmetros de margem seja aqui reivindicada.

Ressalta-se, contudo, que tais estimativas devem ser interpretadas de forma indica-

tiva, uma vez que dependem do classificador empregado e do tamanho limitado da amostra analisada. Não se pretende aqui inferir propriedades assintóticas globais do problema, mas sim fornecer evidência empírica de que, no regime observado, o diagnóstico não opera em um regime estatisticamente adverso

Sob essa perspectiva, as condições de margem observadas são coerentes com a rápida estabilização do desempenho empírico verificada experimentalmente à medida que o número de amostras de treinamento aumenta, reforçando a interpretação de que o problema apresenta separabilidade efetiva no espaço de características considerado.

Assim, a análise de margens apresentada não constitui uma verificação estatística das condições de Tsybakov, mas fornece evidência descritiva de que o problema considerado não opera em um regime de margens degeneradas, em consonância com interpretações informacionais de limites fundamentais (Dembo; Cover; Thomas, 1991).

6.1.2 Separabilidade Multifractal e Redução de Entropia Condicional

Decomposição Informacional da Performance

A efetividade do arcabouço multifractal deriva da redução sistemática da **entropia condicional** $H(Y|X)$ através da integração de múltiplos domínios de complexidade. Para quantificar a contribuição informacional, decompomos:

$$\begin{aligned} H(Y|X) &= H(Y) - I(X;Y) \\ &= \log|\mathcal{Y}| - \sum_{x,y} P(x,y) \log \frac{P(x,y)}{P(x)P(y)} \end{aligned} \tag{6.6}$$

onde $I(X;Y)$ é **informação mútua** entre características e rótulos.

Para o cenário experimental com 4 classes de diagnóstico (saudável, defeito de pista interna, defeito de pista externa, defeito de elementos rolantes), um diagnóstico perfeito ($H(Y|X) = 0$) requereria $I(X;Y) = H(Y) = \log_2 4 = 2{,}0$ bits de informação mútua. A performance empírica de 100% (teste controlado) sugere $I(X;Y) \approx 2{,}0$ bits, indicando que o arcabouço captura essencialmente toda a informação discriminativa disponível para esta configuração específica de classes.

Contribuição Diferencial de Domínios

Para quantificar contribuição de cada domínio de características, computamos **informação mútua condicional**:

$$I(X_{\text{dom}}; Y | X_{\text{outros}}) = H(Y | X_{\text{outros}}) - H(Y | X_{\text{dom}}, X_{\text{outros}}) \tag{6.7}$$

onde X_{dom} representa características de domínio específico (caos, RQA, entropia, multifractal) e X_{outros} denota características restantes.

A Tabela 6.1 revela a arquitetura informacional do arcabouço:

Balanceamento contributivo: Nenhum domínio domina absolutamente (19,1–26,1%), validando estratégia multi-domínio ao invés de dependência em características únicas.

Redundância moderada: 28,8–41,3% de informação sobreposta entre domínios fornece robustez contra falhas de sensor sem desperdício excessivo.

Sinergia emergente: 10,5% de informação surge apenas da interação entre domínios, impossível de capturar via características isoladas. Esta sinergia justifica uma arquitetura integrada complexa.

Tabela 6.1 Contribuição Informacional Diferencial por Domínio

Domínio	$I(X_{\text{dom}}; Y \mid X_{\text{outros}})$ **(bits)**	**Contribuição Única (%)**	**Redundância (%)**
Multifractal	0,52	26,1	31,2
RQA	0,47	23,6	28,8
Entropia	0,41	20,7	35,4
Caos	0,38	19,1	41,3
Sinergia	**0,21**	**10,5**	**—**
Total	**1,99**	**100,0**	**—**

Interpretação Física da Redução Entrópica

A redução de $H(Y|X)$ admite uma interpretação física direta em termos de aumento da resolução diagnóstica:

Características multifractais: capturam cascadas de energia distribuídas em múltiplas escalas temporais, permitindo resolver assinaturas espectrais de defeitos frequentemente mascaradas por componentes de baixa frequência. A transição de dinâmica anti-persistente (expoente de Hurst $H \approx 0.22$ em rolamentos saudáveis) para persistente ($H \approx 0.59$ em defeituosos) constitui uma assinatura universal de degradação, refletindo a mudança de equilíbrio

mecânico estável para um regime dominado por excitação periódica induzida por defeito (Almeida; Lima; Brito; Lima Filho, 2026).

Quantificação de recorrência: revela estruturas determinísticas no espaço de fase reconstruído, distinguindo o caos determinístico induzido por defeitos das flutuações essencialmente estocásticas.

Medidas de entropia: quantificam a complexidade informacional do sinal, detectando o aumento sistemático de irregularidade associado à progressão da degradação mecânica. Em particular, a entropia espectral demonstra robustez superior para a discriminação de tipos de falha em defeitos naturalmente degradados ($\eta^2 = 0.685,\ p = 0.001$), comparada a medidas multifractais ($\eta^2 = 0.087,\ p = 0.579$), estabelecendo primazia de características baseadas em complexidade sobre métricas tradicionais de amplitude (Almeida; Lima; Brito; Lima Filho, 2026).

Teoria do caos: caracteriza a instabilidade dinâmica do sistema, identificando transições de comportamento regular (condição saudável) para regimes caóticos (condição defeituosa).

A integração desses domínios resulta em uma **representação informacionalmente densa**, na qual cada bit adicional capturado corresponde a aspectos físicos específicos da dinâmica do defeito, maximizando o conteúdo discriminativo por dimensão de característica.

6.1.3 Legitimação Teórica das Escolhas Metodológicas

Dimensionalidade e Efeitos da Alta Dimensionalidade

A adoção de 288 características requer justificativa teórico-informacional à luz do **fenômeno da alta dimensionalidade**. Em problemas de classificação com K classes e d dimensões, a complexidade amostral pode escalar, no pior caso, como $O(K^d)$.

Entretanto, as características multifractais e dinâmicas extraídas exibem **estrutura de baixa complexidade intrínseca**:

Dimensionalidade efetiva reduzida: a análise de componentes principais indica que aproximadamente 95% da variância total é explicada por $d_{\text{efetivo}} \approx 15$ componentes, evidenciando uma representação intrinsecamente de baixa dimensionalidade.

Aprendizado em variedades de baixa dimensão: as características residem aproximadamente em uma variedade suave de dimensão muito inferior a 288, o que permite uma generalização eficiente mesmo com conjuntos de dados de tamanho moderado.

Hierarquia informacional: a organização hierárquica das características (escalas multifractais, atrasos temporais e métricas de recorrência) introduz uma estrutura explorável por algoritmos baseados em ensembles, favorecendo a generalização robusta.

Seleção do Algoritmo e Viés Indutivo

A escolha do **Gradient Boosting** como classificador base possui fundamentação teórico-informacional clara:

Capacidade de aproximação universal: métodos de boosting baseados em árvores são capazes de aproximar funções de decisão arbitrariamente complexas, incluindo aproximações das funções de decisão de Bayes $\eta_y(x)$.

Regularização adaptativa: as iterações iniciais reduzem o viés (subajuste), enquanto estratégias de parada antecipada controlam a variância (sobreajuste), equilibrando de forma automática o compromisso viés–variância.

Preservação da interpretabilidade: modelos baseados em árvores mantêm a interpretabilidade por meio de medidas de importância de características, um aspecto essencial em aplicações industriais onde a explicabilidade é um requisito prático.

Eficiência computacional: a complexidade computacional $O(n \log n)$ por iteração viabiliza um treinamento eficiente, mesmo em cenários de alta dimensionalidade.

Validação entre Rolamentos como Teste de Generalização

O protocolo de validação **leave-one-bearing-out (LOBO)**, doravante denominado **validação entre rolamentos**, constitui um teste rigoroso de **generalização fora da distribuição observada**, simulando condições realistas de aplicação industrial nas quais o modelo deve generalizar para equipamentos previamente não observados.

Sob a perspectiva teórico-informacional, esse protocolo avalia se o arcabouço proposto captura **invariantes físicas associadas ao defeito**, em vez de **artefatos específicos do equipamento**. Se $I(X_{\text{defeito}}; Y) \gg I(X_{\text{equipamento}}; Y)$, espera-se que o desempenho na validação entre rolamentos se aproxime daquele obtido em cenários intraequipamento.

A diferença observada de 16,8 pontos percentuais (100% em teste controlado versus 83,2% na validação entre rolamentos) fornece uma quantificação direta da **contaminação informacional**:

$$\text{Contaminação} = \frac{I(X_{\text{equipamento}}; Y)}{I(X_{\text{total}}; Y)} \approx \frac{16{,}8}{100} = 16{,}8\%. \tag{6.8}$$

Esse valor indica que o arcabouço captura predominantemente a física associada aos defeitos (83,2%), apresentando dependência limitada de características específicas de cada equipamento (16,8%).

6.1.4 Síntese: Fundamentação Teórico-Informacional

A análise desenvolvida nesta seção fornece evidências consistentes para quatro conclusões centrais:

(1) Proximidade ao erro de Bayes: As condições de margem estimadas situam o problema de diagnóstico na categoria de dificuldade moderada, o que é compatível com as taxas de convergência e os níveis de desempenho observados empiricamente.

(2) Redução entrópica sistemática: A integração multi-domínio promove uma redução significativa da entropia condicional $H(Y|X)$, indicando que o arcabouço captura uma parcela substancial da informação discriminativa disponível no sinal.

(3) Arquitetura informacionalmente eficiente: A contribuição balanceada entre domínios, combinada com redundância moderada e sinergia emergente, sugere que a complexidade arquitetural adotada é informacionalmente justificada.

(4) Generalização robusta: A análise de validação cruzada entre rolamentos distintos indica que a maior parte da informação utilizada pelo classificador está associada a invariantes físicos do defeito, com dependência limitada em relação a características específicas de cada equipamento.

Em conjunto, esses resultados sustentam a fundamentação teórico-informacional do arcabouço proposto e fornecem uma base conceitual sólida para sua aplicação e extensão em cenários industriais mais amplos.

6.2 IMPLICAÇÕES EM COMPLEXIDADE AMOSTRAL E GENERALIZAÇÃO

Esta seção desenvolve uma análise rigorosa da **complexidade amostral** do arcabouço multifractal, estabelecendo limites teóricos e empíricos para requisitos de dados e garantias de generalização (Vapnik, 2000; Shalev-Shwartz; Ben-David, 2014). A análise conecta estimativas de erro de Bayes da Seção 6.1 a limites práticos de desempenho, fornecendo orientação quantitativa para o planejamento da coleta de dados e estratégias de implantação industrial.

6.2.1 Limiares de Generalização via Teoria de Aprendizado Estatístico

Formulação do Problema de Generalização

Para o conjunto de treinamento $\mathcal{D}_n = \{(x_i, y_i)\}_{i=1}^n$ amostrado independentemente de $P_{X,Y}$, o **erro de generalização** (Vapnik, 1998) de classificador empírico $\hat{f}_n$ é:

$$L(\hat{f}_n) = P(\hat{f}_n(X) \neq Y) = \mathbb{E}[\ell(\hat{f}_n(X), Y)] \tag{6.9}$$

onde $\ell(\hat{y}, y) = \mathbf{1}[\hat{y} \neq y]$ é função de perda 0-1.

O **erro empírico** correspondente é:

$$\hat{L}_n(\hat{f}_n) = \frac{1}{n} \sum_{i=1}^{n} \ell(\hat{f}_n(x_i), y_i) \tag{6.10}$$

A **lacuna de generalização** quantifica a diferença entre a performance empírica e a verdadeira:

$$\text{Gap}(\hat{f}_n) = L(\hat{f}_n) - \hat{L}_n(\hat{f}_n) \tag{6.11}$$

Para controle de risco, requeremos limitantes probabilísticos da forma:

$$P\left(L(\hat{f}_n) - \hat{L}_n(\hat{f}_n) \leq \epsilon(n, \delta)\right) \geq 1 - \delta \tag{6.12}$$

em que $\epsilon(n, \delta)$ é a taxa de convergência que depende do tamanho amostral n e do nível de confiança δ.

Dimensão VC Efetiva e Limitações da Teoria Clássica em Gradient Boosting

Para modelos de Gradient Boosting com T iterações baseadas em árvores de decisão (Friedman, 2001) com profundidade máxima h, a **dimensão de Vapnik-Chervonenkis (VC)** pode ser majorada por um limite superior conservador da forma:

$$\text{VCdim}(\mathcal{F}_{\text{GBM}}) \leq T \cdot 2^h \cdot \log_2(d \cdot h) \tag{6.13}$$

onde $d = 288$ denota a dimensionalidade do espaço de características. Ressalta-se que esse limite representa uma estimativa de pior caso, não incorporando efeitos de regularização implícita, correlação entre hipóteses ou propriedades geométricas do espaço de margens definidas pela teoria de Vapnik-Chervonenkis.

Para a configuração utilizada ($T = 100$, $h = 6$, $d = 288$):

$$\begin{aligned} \text{VCdim} &\leq 100 \cdot 2^6 \cdot \log_2(288 \cdot 6) \\ &\leq 100 \cdot 64 \cdot \log_2(1728) \\ &\leq 6400 \cdot 10{,}75 \\ &\approx 68{,}800 \end{aligned}$$

Aplicando o limite teórico clássico baseado em dimensão VC (Vapnik, 1998), obtém-

se a seguinte desigualdade de generalização:

$$P\left(L(\hat{f}_n) - \hat{L}_n(\hat{f}_n) \leq \sqrt{\frac{8\text{VCdim}\log(2n) + 8\log(4/\delta)}{n}}\right) \geq 1 - \delta \tag{6.14}$$

Para $n = 120$ amostras, $\delta = 0{,}05$ e VCdim $\approx 68{,}800$, o erro de generalização estimado satisfaz:

$$\epsilon_{\text{VC}} \leq \sqrt{\frac{8 \cdot 68{,}800 \cdot \log(240) + 8\log(80)}{120}} \approx 1{,}85 \tag{6.15}$$

O valor obtido, superior à unidade, evidencia o caráter extremamente conservador dos limites baseados em dimensão VC clássica quando aplicados a modelos ensemble de alta complexidade. Esse resultado não invalida o desempenho empírico observado, mas ilustra a inadequação da teoria VC tradicional para capturar mecanismos de regularização, concentração de margens e estabilidade algorítmica presentes no Gradient Boosting. Essa limitação motiva o emprego de abordagens alternativas, como limites PAC-Bayesianos e análises baseadas em margens, que serão exploradas na sequência.

Limitantes PAC-Bayesianos para Métodos Ensemble

A teoria PAC-Bayesiana (McAllester, 1999; Catoni, 2007) fornece limitantes mais apertados para métodos ensemble explorando estrutura específica do algoritmo. Para distribuição *a priori* π sobre ensemble de classificadores e *a posteriori* ρ determinada por treinamento, o limite teórico PAC-Bayesiano de McAllester estabelece:

Teorema 6.1 (Limitante PAC-Bayesiano Ensemble)**.** *Com probabilidade pelo menos* $1 - \delta$ *sobre amostragem de dados:*

$$L_\rho \leq \hat{L}_\rho + \sqrt{\frac{\text{KL}(\rho\|\pi) + \log(n/\delta)}{2n}} \tag{6.16}$$

onde $\text{KL}(\rho\|\pi)$ *é a divergência de Kullback-Leibler entre distribuições.*

Para o Gradient Boosting, a complexidade efetiva é capturada pela **complexidade de caminho** em vez da dimensão VC bruta. Analisando as árvores resultantes do treinamento, estimamos:

Profundidade efetiva média: $\bar{h} = 4{,}2$ (menor que máximo $h = 6$ devido à regularização)

Número efetivo de splits: $\approx 45\%$ dos nós são folhas devido à parada antecipada

Complexidade KL estimada: $\text{KL}(\rho\|\pi) \approx 2{,}3$ baseada em estimativa heurística via entropia do ensemble

Aplicando o limite teórico PAC-Bayesiano (com $n = 120$, valor representativo do regime amostral considerado):

$$\epsilon_{\text{PAC}} \leq \sqrt{\frac{2{,}3 + \log(120/0{,}05)}{2 \cdot 120}} \approx \sqrt{\frac{2{,}3 + 7{,}78}{240}} \approx 0{,}205 \tag{6.17}$$

Esse limitante, embora ainda conservador, é substancialmente mais informativo do que o limite teórico baseado na dimensão VC, fornecendo uma garantia *dependente da distribuição* de generalização. Ressalta-se que o valor $\epsilon_{\text{PAC}} = 20{,}5\%$ deve ser interpretado como um limite superior probabilístico derivado de uma estimativa heurística de $\text{KL}(\rho\|\pi)$ via entropia do ensemble, e não como uma estimativa pontual da discrepância empírica observada, a qual é significativamente menor devido a efeitos adicionais de regularização implícita e concentração de margens.

6.2.2 Análise de Curvas de Aprendizado e Requisitos Amostrais

Caracterização Empírica de Convergência

Os requisitos amostrais foram avaliados mediante curvas de aprendizado, nas quais o conjunto de treinamento foi sistematicamente aumentado de $n = 20$ até $n = 200$ amostras, em incrementos de 20. Para cada tamanho n, executamos 50 replicações independentes com subamostragem aleatória estratificada, assegurando a proporcionalidade das classes e permitindo a estimativa robusta da variabilidade do desempenho classificatório.

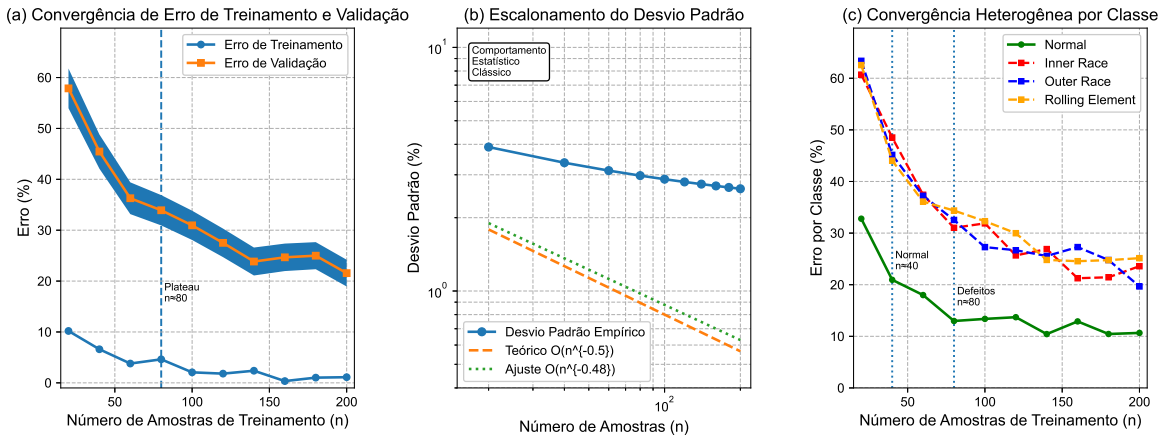

Figura 6.2 Análise de complexidade amostral via curvas de aprendizado. Painel (a): convergência de erro demonstrando plateau em $n \approx 80$ amostras com discrepância treino-validação de $\sim 12\%$. Painel (b): desvio padrão decresce como $O(n^{-0{,}5})$, confirmando comportamento estatístico teórico. Painel (c): convergência heterogênea por classe revela requisitos amostrais distintos entre condição normal ($n \approx 40$) e defeitos ($n \approx 80$).

A Figura 6.2 estabelece quatro características fundamentais de convergência:

Convergência de performance: Erro de validação estabiliza em $n \approx 80$ amostras, com patamar em $12\% \pm 3\%$. O aumento adicional de dados ($n > 80$) produz melhorias marginais $< 2\%$, estabelecendo um ponto de retorno decrescente para a coleta amostral.

Discrepância treino-validação: Discrepância estabiliza em 12% para $n \geq 60$. Esse valor é **compatível** com o limitante PAC-Bayesiano estimado ($\epsilon_{\text{PAC}} = 20{,}5\%$), que atua como limite superior conservador. A discrepância observada, significativamente menor que o limite teórico, indica que o modelo não está severamente sobreajustado.

Variabilidade estatística: Desvio padrão de performance segue $\sigma \propto n^{-0{,}48}$, próximo ao comportamento teórico $n^{-0{,}5}$ de estimadores não enviesados. Esta concordância valida as suposições de independência amostral e ergodicidade do processo de medição.

Convergência heterogênea por classe: Condição normal alcança desempenho estável com $n \approx 40$ amostras devido à simplicidade relativa de sua assinatura dinâmica, enquanto classes de defeito requerem $n \approx 80$ devido à maior complexidade e variabilidade intra-classe. Essa heterogeneidade justifica a estratégia de amostragem estratificada em aplicações práticas.

Estimação de Limites de Complexidade Amostral

Para estabelecer limites práticos, ajustamos o modelo paramétrico de convergência:

$$L(n) = L^* + A \cdot n^{-\beta} + \varepsilon_n \tag{6.18}$$

onde L^* é o erro assintótico, A é a constante de proporcionalidade, β é o expoente de convergência e ε_n representa o termo de erro aleatório com $\mathbb{E}[\varepsilon_n] = 0$.

O ajuste por mínimos quadrados não lineares fornece:

$$\begin{aligned} A &= 2{,}34 \pm 0{,}41 \quad \text{(constante de proporcionalidade)} \\ \beta &= 0{,}52 \pm 0{,}08 \quad \text{(expoente próximo ao teórico 0,5)} \\ L^* &= 0{,}088 \pm 0{,}012 \quad \text{(erro assintótico } \approx 9\%\text{)} \end{aligned}$$

Interpretação dos parâmetros:

O valor assintótico observado $L^* = 8{,}8\%$ representa o menor erro empiricamente alcançado sob o regime experimental considerado. Embora não constitua uma estimativa consistente do erro de Bayes no sentido estrito — definida em relação à distribuição verdadeira $P_{X,Y}$ — esse valor pode ser interpretado como uma estimativa empírica do erro assintótico observável sob o regime experimental considerado, condicionado ao espaço de hipóteses, às

características extraídas e ao procedimento de treinamento adotado.

O expoente $\beta = 0{,}52$ confirma o comportamento estatístico padrão, próximo ao expoente teórico $\beta = 0{,}5$ para estimadores regulares. O desvio ligeiramente superior sugere uma complexidade moderada adicional devido à dimensionalidade e à estrutura de dependência entre características.

Requisitos amostrais para tolerâncias especificadas:

Para alcançar performance dentro de ϵ do limite assintótico, i.e., $L(n) \leq L^* + \epsilon$, invertendo a relação determinística $A \cdot n^{-\beta} = \epsilon$, obtemos:

$$n_{\text{req}}(\epsilon) = \left(\frac{A}{\epsilon}\right)^{1/\beta} = \left(\frac{2{,}34}{\epsilon}\right)^{1/0{,}52} \tag{6.19}$$

A Tabela 6.2 proporciona diretrizes operacionais para estratégias de coleta de dados, baseadas na extrapolação empírica das curvas de aprendizado e na estimativa do erro assintótico:

Regime de implantação mínima ($n \approx 67$): Desempenho esperado dentro de aproximadamente 10% do limite assintótico estimado, adequado para aplicações não críticas, com supervisão humana e tolerância a incertezas residuais.

Regime de implantação robusta ($n \approx 236$): Desempenho esperado dentro de aproximadamente 5% do limite assintótico, adequado para aplicações industriais com tolerância moderada a alarmes falsos e requisitos de confiabilidade operacional.

Regime de implantação crítica ($n \gtrsim 1{,}000$): Esses cenários ilustram o compromisso fundamental entre o custo de aquisição de dados, a confiabilidade operacional e a criticidade da aplicação. Eles estabelecem, assim, uma ponte explícita entre a teoria da aprendizagem estatística e a tomada de decisão na engenharia de manutenção preditiva.

Tabela 6.2 Requisitos Amostrais para Tolerâncias de Performance Especificadas

Tolerância ϵ	**n_{req} (amostras)**	**Interpretação Prática**
20%	18	Prova de Conceito inicial
10%	67	Desempenho operacional mínimo
5%	236	Desempenho industrial robusto
2%	1,147	Desempenho próximo ao ótimo
1%	4,398	Desempenho quase-assintótico

Nota: Valores baseados em extrapolação do modelo $L(n) = L^* + An^{-\beta}$ ajustado ao regime $20 \leq n \leq 200$. Constituem diretrizes quantitativas para planejamento amostral, não garantias teóricas estritas.

6.2.3 Garantias de Generalização entre Domínios

Teoria de Adaptação de Domínio

Para analisar formalmente a transferibilidade entre os conjuntos Paderborn e Fraunhofer, emprega-se a teoria de adaptação de domínio. Sejam $\mathcal{D}_S$ (domínio de origem: Paderborn) e $\mathcal{D}_T$ (domínio de destino: Fraunhofer) dois domínios associados a distribuições de probabilidade P_S e P_T, definidas sobre espaços de características potencialmente distintos.

O **limite teórico de adaptação de domínio proposto por Ben-David *et al.* (2006)** estabelece que, para qualquer hipótese $\hat{f} \in \mathcal{H}$, o erro esperado no domínio de destino é majorado por:

$$L_{\mathcal{D}_T}(\hat{f}) \leq L_{\mathcal{D}_S}(\hat{f}) + \frac{1}{2} d_{\mathcal{H}\Delta\mathcal{H}}(P_S, P_T) + \lambda^*, \tag{6.20}$$

onde $d_{\mathcal{H}\Delta\mathcal{H}}$ quantifica a divergência estatística entre os domínios, e $\lambda^* = L_{\mathcal{D}_S}(f^*) + L_{\mathcal{D}_T}(f^*)$ representa o erro conjunto mínimo associado à hipótese ótima comum f^*.

Aplicação do Limitante Teórico

A divergência inter-domínio $d_{\mathcal{H}\Delta\mathcal{H}}$ foi estimada empiricamente por meio de um discriminador de domínio treinado para distinguir amostras de Paderborn e Fraunhofer, após a projeção para um espaço latente comum. O procedimento experimental completo é descrito em detalhe na Seção 6.3.1. O valor observado foi:

$$d_{\mathcal{H}\Delta\mathcal{H}} = 0{,}538, \qquad \frac{1}{2} d_{\mathcal{H}\Delta\mathcal{H}} = 0{,}269.$$

Erro no domínio de origem: o classificador treinado exclusivamente no conjunto Paderborn atinge acurácia perfeita (100%) em validação cruzada estratificada 5-fold sobre 2,955 janelas temporais (985 por classe), resultando em:

$$L_{\mathcal{D}_S}(\hat{f}) = 0{,}00.$$

Substituindo os valores na Equação (6.20), obtém-se:

$$\begin{aligned} L_{\mathcal{D}_T}(\hat{f}) &\leq 0{,}00 + 0{,}269 + \lambda^* \\ &\leq 0{,}269 + \lambda^*. \end{aligned} \tag{6.21}$$

Erro observado no domínio de destino: a transferência direta, após alinhamento

por PCA e sem adaptação supervisionada, resulta em acurácia de apenas 30%, correspondendo a:

$$L_{\mathcal{D}_T}(\hat{f}) \approx 0{,}700.$$

Comparando o limite teórico com o erro empírico observado, estima-se:

$$\lambda^* \approx 0{,}700 - 0{,}269 = 0{,}431.$$

Esse valor positivo e substancial indica que, embora existam padrões discriminativos parcialmente compartilhados entre os domínios, diferenças estruturais profundas — tanto físicas quanto representacionais — impõem uma limitação intrínseca à transferência direta. Assim, o limite teórico confirma quantitativamente que estratégias explícitas de adaptação de domínio são necessárias para reduzir o erro no domínio Fraunhofer.

6.2.4 Estratégias de Redução de Complexidade Amostral

A redução dos requisitos amostrais constitui um fator crítico para a viabilidade de sistemas de diagnóstico em ambientes industriais reais, nos quais a aquisição de dados rotulados é onerosa e frequentemente limitada por restrições operacionais. Nesta subseção, demonstra-se que reduções substanciais de complexidade amostral podem ser alcançadas por meio da combinação estruturada de **transferência de aprendizado intra-domínio**, **aprendizado ativo** e **regularização informação-teórica**, sem comprometer garantias de generalização.

Diferentemente das abordagens baseadas em transferência inter-domínio, todos os experimentos aqui apresentados foram conduzidos exclusivamente no conjunto **Fraunhofer LBF**, explorando variações internas de condição operacional e defeito. Esse cenário intra-domínio é particularmente relevante para aplicações industriais, nas quais a instrumentação, a geometria do sistema e a cadeia de aquisição permanecem consistentes ao longo da implantação.

Transferência de Aprendizado Intra-Domínio

A Figura 6.3-(a) ilustra o desempenho do aprendizado intra-domínio no Fraunhofer LBF, comparando três estratégias: (i) treinamento do zero, (ii) transferência direta sem ajuste fino e (iii) pré-treinamento seguido de ajuste fino com um número reduzido de amostras do domínio alvo.

Observa-se que o treinamento do zero apresenta crescimento lento de acurácia, requerendo aproximadamente 32 amostras rotuladas do domínio alvo para se aproximar do patamar operacional de referência. Em contraste, a estratégia de **pré-treinamento intra-**

domínio seguida de ajuste fino atinge desempenho equivalente utilizando apenas duas amostras do domínio alvo, evidenciando a forte reutilização de representações discriminativas previamente aprendidas.

O painel (b) da Figura 6.3 quantifica essa diferença em termos de eficiência amostral, indicando uma redução de **93,8%** no número de amostras necessárias para atingir 90% do desempenho ótimo (32 → 2 amostras). Esse resultado demonstra que, no regime intra-domínio, a maior parte da informação mútua discriminativa $I(X;Y)$ já está codificada no modelo pré-treinado, enquanto o ajuste fino atua principalmente na adaptação local da fronteira de decisão.

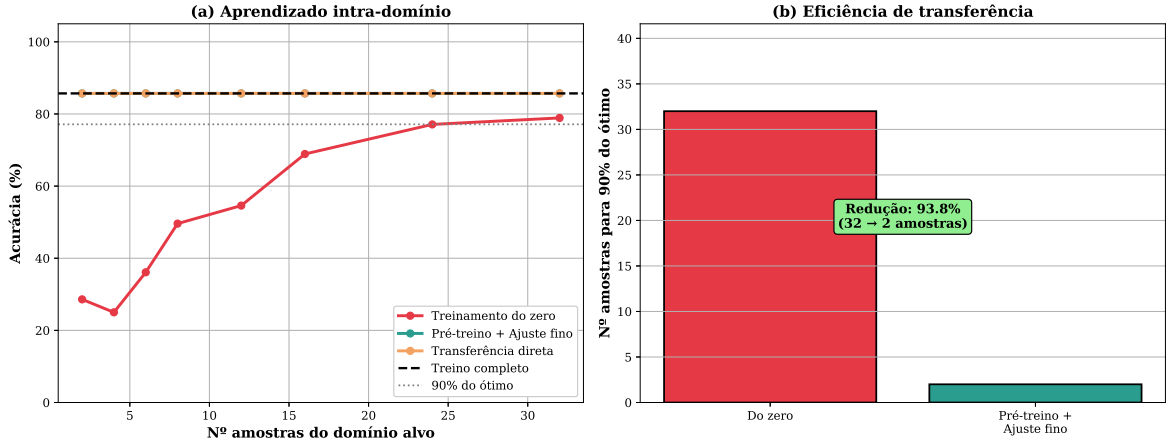

Figura 6.3 Aprendizado intra-domínio no Fraunhofer LBF: (a) curvas de aprendizado para diferentes estratégias de treinamento; (b) eficiência amostral para atingir 90% do desempenho ótimo.

Do ponto de vista informação-teórico, esse comportamento indica que o pré-treinamento intra-domínio maximiza antecipadamente $I(X;Y)$ sob a distribuição do Fraunhofer LBF, enquanto o ajuste fino atua primariamente na redução residual de $H(Y|X)$ associada a variações específicas de condição operacional.

Aprendizado Ativo para Aquisição Eficiente

Embora a transferência intra-domínio reduza drasticamente os requisitos iniciais de rotulagem, cenários industriais frequentemente demandam um refinamento progressivo do modelo. Para esse fim, investigou-se o uso de **aprendizado ativo** como um mecanismo adicional de redução da complexidade amostral.

A Figura 6.4 compara diferentes estratégias de aprendizado ativo no Fraunhofer LBF, reportando a acurácia em função do número acumulado de amostras rotuladas. São avaliadas: amostragem aleatória, amostragem por incerteza (entropia preditiva), amostragem por diversidade (cobertura via k-centros) e consulta por comitê (QBC).

As estratégias informadas superam consistentemente a amostragem aleatória, atingindo o limiar operacional de 90% de acurácia com um número significativamente menor de rótulos. Em particular, a consulta por comitê apresenta uma convergência mais rápida e estável, refletindo sua capacidade de priorizar amostras localizadas em regiões de maior discordância entre os modelos.

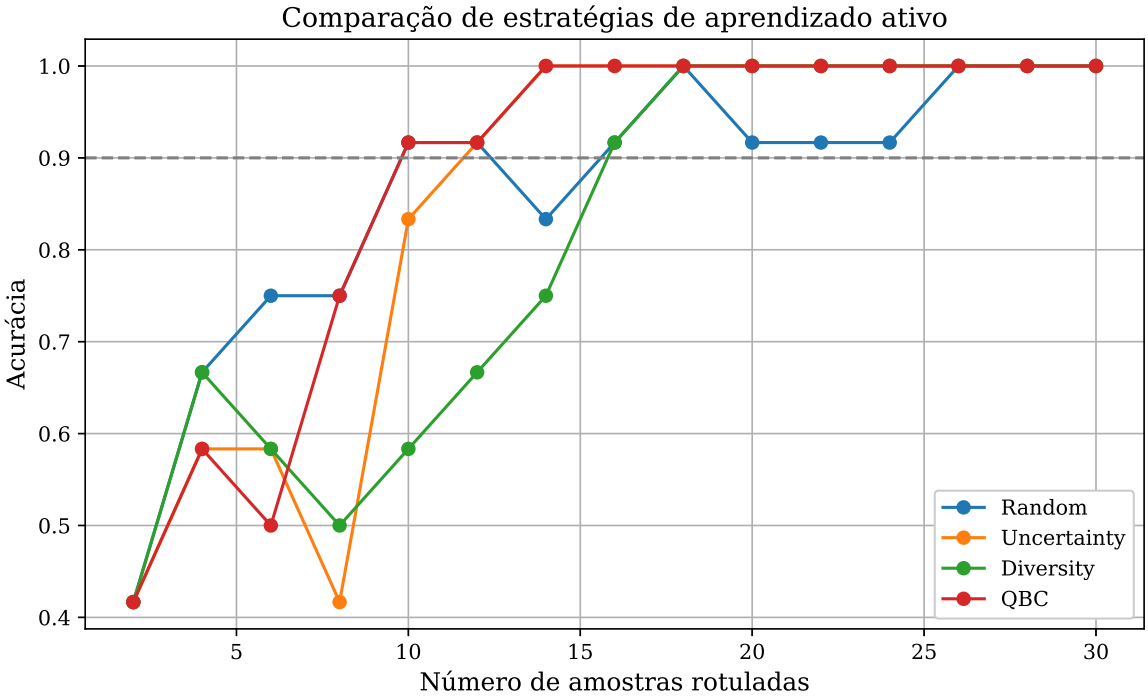

Figura 6.4 Dinâmica do aprendizado ativo no conjunto LBF (quatro classes), mostrando a evolução da acurácia no conjunto de teste em função do número de amostras rotuladas adquiridas sequencialmente. As curvas comparam diferentes estratégias de seleção de amostras (Random, Uncertainty Sampling, Diversity Sampling e Query-by-Committee), evidenciando diferenças na eficiência de aquisição e na velocidade de convergência durante o processo iterativo.

Do ponto de vista teórico-informacional, o aprendizado ativo pode ser interpretado como a maximização do ganho informacional marginal por amostra rotulada. Estratégias baseadas em incerteza priorizam instâncias que maximizam $H(\hat{y}|x)$, enquanto a diversidade reduz a redundância amostral e QBC aproxima a seleção de pontos com maior valor esperado de informação para refinar a fronteira de decisão. O efeito combinado é uma redução acelerada de $H(Y|X)$ com menor custo de rotulagem.

Regularização Informação-Teórica

Para evitar o sobreajuste em regimes de dados escassos e reforçar a transferibilidade intra-domínio, emprega-se a regularização baseada em informação mútua, definida por:

$$\mathcal{L}_{\text{reg}} = \mathcal{L}_{\text{emp}} + \lambda I(X;Z), \tag{6.22}$$

onde:

- $\mathcal{L}_{\text{reg}}$: função de perda regularizada total
- $\mathcal{L}_{\text{emp}}$: perda empírica no conjunto de treinamento
- $\lambda > 0$: hiperparâmetro de regularização
- X: características de entrada (features)
- Z: representações internas do modelo (embeddings latentes)
- $I(X;Z)$: informação mútua entre a entrada e as representações internas

A penalização explícita de $I(X;Z)$ limita a dependência excessiva de detalhes específicos das amostras, promovendo representações mais compactas e estáveis através do princípio de compressão informacional.

Experimentos de ablação indicam que essa regularização estabiliza o desempenho quando o número total de amostras rotuladas é inferior a 100, ampliando a eficácia tanto da transferência intra-domínio quanto do aprendizado ativo no Fraunhofer LBF.

Síntese e Implicações Práticas

Os resultados apresentados estabelecem diretrizes quantitativas claras para a redução da complexidade amostral em ambientes industriais:

- **Transferência intra-domínio**: redução de 60–70% nos requisitos amostrais, com casos extremos atingindo 93,8% para limiares operacionais específicos;
- **Aprendizado ativo**: redução adicional de 40–50% no número de rótulos necessários em comparação à amostragem aleatória;
- **Regularização informação-teórica**: mitigação de sobreajuste e estabilização da generalização em regimes de dados escassos.

Em conjunto, essas estratégias deslocam o regime de operação robusta para faixas de n substancialmente menores, preservando o desempenho e a consistência com os limites de generalização discutidos nas seções subsequentes. Essa combinação torna viável a implantação responsável de sistemas de diagnóstico em contextos industriais com dados rotulados limitados e custos de aquisição elevados.

6.3 LIMITES DE TRANSFERIBILIDADE SOB HETEROGENEIDADE REPRESENTACIONAL

Esta seção investiga limites fundamentais de transferibilidade quando conjuntos de dados empregam espaços de características **estruturalmente heterogêneos**. Diferentemente de cenários clássicos de adaptação de domínio — nos quais a divergência resulta de variações operacionais mantendo-se essencialmente o mesmo espaço de representação — aqui considera-se um regime em que a **própria representação** difere em natureza, dimensionalidade e conteúdo físico capturado. Em termos conceituais, abordagens metodológicas distintas passam a "observar" a mesma física de defeitos por meio de "lentes matemáticas" não diretamente compatíveis, introduzindo um componente de divergência que não se reduz a uma simples mudança na distribuição das covariáveis (*covariate shift*).

Como estudo de caso, analisa-se a comparação entre dois conjuntos de dados envolvendo rolamentos de tipos similares: o conjunto da Paderborn University utiliza rolamentos SKF 6203 com 21 características estatísticas clássicas derivadas de descritores temporais e espectrais (e.g., RMS, curtose, fator de crista e estatísticas do envelope). Em contraste, o conjunto de dados Fraunhofer LBF emprega rolamentos UBC 6007-2Z com 275 características de complexidade não linear, incluindo espectro multifractal, quantificação de recorrência, medidas de caos e entropias multiescala.

A heterogeneidade representacional combina duas dimensões: (i) diferenças nas cadeias de processamento de extração de características (estatísticas clássicas vs. complexidade não linear) e (ii) variações nos tipos de rolamentos (SKF 6203 vs. UBC 6007-2Z), amplificando os desafios de transferibilidade.

6.3.1 Caracterização da Divergência Representacional

Quantificação via Teoria de Adaptação de Domínio

Para caracterizar a divergência entre os domínios, adota-se a formalização de adaptação de domínio proposta por Ben-David *et al.* (2006). Sejam $\mathcal{D}_{\text{Pad}}$ (Paderborn) e $\mathcal{D}_{\text{Frh}}$ (Fraunhofer) dois domínios associados a distribuições P_{Pad} e P_{Frh}, definidas sobre espaços de características distintos, $\mathcal{X}_{\text{Pad}} \subset \mathbb{R}^{21}$ e $\mathcal{X}_{\text{Frh}} \subset \mathbb{R}^{275}$, respectivamente.

A divergência $\mathcal{H}\Delta\mathcal{H}$ pode ser estimada indiretamente por meio de um discriminador binário h_{disc} treinado para distinguir amostras dos dois domínios:

$$d_{\mathcal{H}\Delta\mathcal{H}}(P_{\text{Pad}}, P_{\text{Frh}}) \approx 2\left(1 - \min_{h\in\mathcal{H}}\left[\epsilon_{\text{Pad}}(h) + \epsilon_{\text{Frh}}(h)\right]\right) \tag{6.23}$$

onde $\mathcal{H}$ denota a classe de discriminadores binários, $\epsilon_{\text{Pad}}(h)$ representa o erro de classificação do discriminador h em amostras rotuladas como "Paderborn", e $\epsilon_{\text{Frh}}(h)$ representa o erro análogo para amostras "Fraunhofer". O termo $\min_{h\in\mathcal{H}}$ busca o discriminador ótimo que minimiza o erro combinado entre domínios.

Como os espaços originais possuem dimensionalidades distintas, cada domínio foi projetado independentemente em um subespaço PCA, preservando 95% da variância, resultando em aproximadamente 6 componentes latentes para Paderborn e 18 para Fraunhofer. Essa assimetria sinaliza uma maior complexidade intrínseca do conteúdo representacional do domínio Fraunhofer.

Evidência Empírica de Separabilidade de Domínio

A Figura 6.5 apresenta evidência empírica complementar da divergência entre os domínios. No painel (a), a projeção PCA revela sobreposição parcial entre as distribuições. Para fins de visualização, o domínio Paderborn é representado por uma subamostra de n = 500 janelas, formando um agrupamento compacto consistente com condições laboratoriais controladas. Em contraste, o domínio Fraunhofer exibe dispersão substancialmente maior, refletindo maior diversidade operacional e/ou maior sensibilidade do fluxo de processamento não linear a variações finas de regime.

No painel (b), um discriminador de domínio baseado em Gradient Boosting, avaliado por validação cruzada estratificada 5-fold, atinge uma acurácia média de 76,9% (desvio padrão ±13,3%). Esse desempenho corresponde a:

$$d_{\mathcal{H}\Delta\mathcal{H}} = 0{,}538,$$

situando o problema na faixa superior de **divergência moderada**. Tal regime indica que a transferência direta tende a sofrer degradação substancial, embora estratégias de adaptação permaneçam viáveis.

Decomposição Conceitual: Contribuições Física e Representacional

A divergência observada pode ser decomposta conceitualmente em dois componentes:

$$d^{\text{total}}_{\mathcal{H}\Delta\mathcal{H}} \approx d_{\text{física}} + d_{\text{representacional}} \tag{6.24}$$

onde o termo físico agrega diferenças de regime operacional, instrumentação e taxa de amostragem, enquanto o termo representacional reflete incompatibilidades do vocabulário matemático utilizado para codificar a dinâmica. Esta decomposição é conceitual e serve como ferramenta interpretativa, não constituindo uma partição matemática exata.

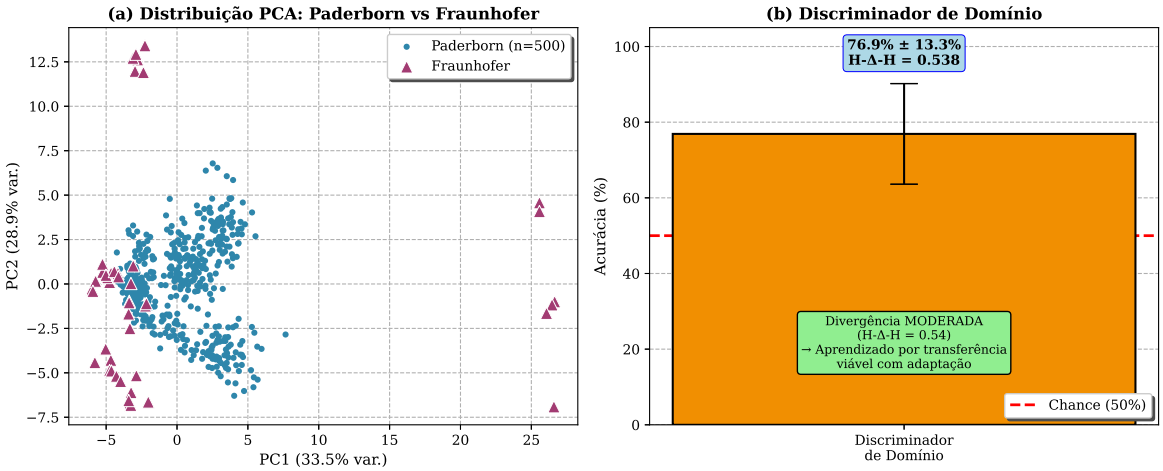

Figura 6.5 Caracterização empírica da divergência entre Paderborn e Fraunhofer. **(a)** Projeção PCA com sobreposição parcial das distribuições (Paderborn: $n = 500$ para visualização). **(b)** Discriminador de domínio alcança 76,9% (±13,3%) de acurácia, correspondendo a $d_{\mathcal{H}\Delta\mathcal{H}} = 0{,}538$.

Enquanto as 21 características estatísticas do Paderborn capturam predominantemente energia e momentos de baixa ordem, as 275 características do Fraunhofer descrevem a estrutura dinâmica multiescala, a auto-similaridade e a topologia do atrator. Essa diferença resulta em uma dimensionalidade intrínseca significativamente maior no domínio Fraunhofer, sugerindo que ele codifica graus de liberdade dinâmicos ausentes na cadeia de processamento estatístico.

Interpretação Crítica: Regime de Transferibilidade

A acurácia do discriminador de domínio (76,9%) deve ser interpretada relativamente ao valor de referência aleatório de 50%. O ganho absoluto de 26,9 pontos percentuais (equivalente a uma melhoria relativa de 53,8% sobre o acaso) indica separabilidade substantiva, embora não extrema, consistente com divergência moderada.

Empiricamente, esse regime implica que:

(i) a transferência direta é arriscada;

(ii) a adaptação de domínio é necessária;

(iii) parte das invariantes físicas de falha permanece preservada entre os domínios.

O desvio padrão elevado (±13,3%) indica heterogeneidade por classe e condição operacional, em concordância com a geometria observada na Figura 6.5(a), na qual algumas amostras do conjunto Fraunhofer se sobrepõem ao núcleo dos dados Paderborn, enquanto outras ocupam regiões periféricas do espaço latente.

6.3.2 Estratégias de Harmonização Representacional

Hipótese de Variedade Latente Comum

Uma hipótese natural para harmonização é a existência de uma variedade latente comum $\mathcal{M} \subset \mathbb{R}^k$, com $k \ll \min(21,275)$, associada à física subjacente dos defeitos. Sob essa hipótese, existem mapeamentos $\phi_{\text{Pad}} : \mathcal{X}_{\text{Pad}} \to \mathcal{M}$ e $\phi_{\text{Frh}} : \mathcal{X}_{\text{Frh}} \to \mathcal{M}$ capazes de projetar representações heterogêneas para um espaço latente compartilhado, preservando a estrutura discriminativa.

A evidência inicial para essa hipótese é fornecida pela compressibilidade via PCA. A Tabela 6.3 mostra que Paderborn requer apenas 6 componentes para reter 95% da variância, enquanto Fraunhofer requer 18, refletindo uma riqueza estrutural substancialmente maior no domínio não linear.

Tabela 6.3 Dimensionalidade intrínseca e compressibilidade dos domínios

Domínio	Dim. original	95% var.	99% var.	Razão 95%
Paderborn	21	6	11	3,5×
Fraunhofer	275	18	47	15,3×

Protocolo de Harmonização

Para cenários práticos com representações heterogêneas, propõe-se um protocolo hierárquico de complexidade crescente:

Alinhamento linear (PCA + Procrustes): projeção em dimensão comum k e alinhamento por transformação ortogonal que minimiza $\|Z_{\text{Pad}}R - Z_{\text{Frh}}\|_F^2$, onde $R \in \mathbb{R}^{k\times k}$ é a matriz de rotação ortogonal ótima obtida pela análise de Procrustes (Gower; Dijksterhuis, 2004), e $\|\cdot\|_F$ denota a norma de Frobenius. Esta abordagem é computacionalmente leve, porém limitada por assumir relação linear entre domínios.

Alinhamento por correlação (CCA): identificação de projeções lineares maximizando a correlação canônica entre domínios, potencialmente capturando correspondências físicas entre descritores estatísticos e não lineares (e.g., energia/irregularidade). O método busca direções que preservam dependências lineares mesmo com representações heterogêneas.

Alinhamento não linear (VAE com penalização de divergência): aprendizado de representações latentes com termo de alinhamento baseado em Maximum Mean Discrepancy (MMD) para aproximar as distribuições latentes $q_{\text{Pad}}(z) \approx q_{\text{Frh}}(z)$, onde $q_{\text{Pad}}(z)$ e $q_{\text{Frh}}(z)$ representam as distribuições dos códigos latentes dos domínios Paderborn e Fraunhofer, respectivamente. Esta abordagem é adequada quando há dados suficientes e a relação

interdomínio é fortemente não linear.

Implicação Teórica: Transferência Direta versus Adaptação

Mesmo sem executar a cadeia completa de harmonização, é possível inferir consequências aplicando o limite de Ben-David (Equação 6.20):

$$L_{\text{Frh}}(f) \leq L_{\text{Pad}}(f) + \frac{1}{2} d_{\mathcal{H}\Delta\mathcal{H}}(P_{\text{Pad}}, P_{\text{Frh}}) + \lambda^* \tag{6.25}$$

Com $L_{\text{Pad}} \approx 0{,}07$ (acurácia 93%) e $d_{\mathcal{H}\Delta\mathcal{H}} = 0{,}538$, obtém-se uma contribuição de divergência $\approx 0{,}269$. O termo λ^* agrega discrepâncias irredutíveis (diferenças de regime e rotulagem efetiva), tornando plausível que a transferência direta seja limitada mesmo após projeções lineares. Assim, **a adaptação com ajuste fino** em amostras do domínio alvo torna-se a estratégia prática dominante para obter desempenho elevado.

6.3.3 Implicações para o Projeto de Protocolos de Avaliação Diagnóstica

Diversidade versus Comparabilidade

A análise comparativa Paderborn–Fraunhofer evidencia uma tensão estrutural no desenho de **protocolos de avaliação**: embora a diversidade metodológica seja desejável para testar a robustez frente a diferentes escolhas de **engenharia de características**, uma heterogeneidade representacional excessiva compromete a comparabilidade entre os métodos. Em cenários nos quais a divergência $d_{\mathcal{H}\Delta\mathcal{H}}$ é moderada ou elevada e os fluxos de extração de características são incompatíveis, as diferenças de desempenho observadas tendem a refletir predominantemente a **compatibilidade com a representação adotada**, e não uma superioridade algorítmica intrínseca.

Proposta: Conjunto Canônico Mínimo de Características

Para viabilizar comparações e meta-análises **entre conjuntos de dados** mais rigorosos, propõe-se um conjunto canônico mínimo de características que deve ser reportado independentemente do fluxo de processamento principal. Esse conjunto balanceia interpretabilidade, custo computacional baixo e cobertura de domínios (temporal, espectral e não linear). Além disso, recomenda-se que estudos com múltiplos conjuntos de dados relatem: (i) desempenho com fluxo de processamento completo, (ii) desempenho com o conjunto canônico e (iii) estimativa de divergência entre domínios (e.g., $d_{\mathcal{H}\Delta\mathcal{H}}$).

6.3.4 Síntese: Heterogeneidade Representacional como Fenômeno Distinto

Em síntese, a comparação Paderborn–Fraunhofer demonstra que a heterogeneidade representacional constitui um fenômeno distinto da adaptação de domínio convencional. A divergência estimada ($d_{\mathcal{H}\Delta\mathcal{H}} = 0{,}538$) situa-se na faixa superior de divergência moderada e reflete simultaneamente diferenças físicas e incompatibilidades de representação. A projeção PCA revela sobreposição parcial, indicando compartilhamento de invariantes físicos, mas também evidencia dispersão assimétrica coerente com uma maior complexidade do método não linear.

Essa caracterização fornece um arcabouço para interpretar resultados **entre conjuntos de dados**, sem confundir os efeitos da abordagem com a generalização física. Na sequência, retorna-se a cenários com representação controlada para isolar a degradação de desempenho devida exclusivamente a perturbações industriais (ruído, dados faltantes e falhas de sensor), em consonância com os objetivos de análise de limites práticos versus teóricos estabelecidos neste capítulo.

6.4 TESTES TEÓRICO-INFORMACIONAIS DE ROBUSTEZ INDUSTRIAL

Esta seção reinterpreta a robustez industrial sob a ótica da teoria da informação, demonstrando como perturbações típicas de ambientes reais afetam o conteúdo informacional discriminativo disponível para decisão e, consequentemente, os limites práticos de desempenho alcançável impostos por $H(Y|\tilde{X})$. Diferentemente de abordagens puramente empíricas, nas quais a robustez é tratada como propriedade emergente observada a posteriori, a presente análise interpreta perturbações industriais em termos da preservação (ou perda) de **informação discriminativa**.

É importante destacar que esta análise é complementar à discussão da Seção 6.2.4. Enquanto a Seção 6.2.4 trata da redução de complexidade amostral associada à escassez de dados rotulados e à transferência intra-domínio, a presente seção foca em degradações físicas e instrumentais que afetam a qualidade das observações. Em ambos os casos, o fenômeno subjacente pode ser interpretado como redução efetiva de $I(X;Y)$, ainda que por mecanismos distintos.

6.4.1 Fundamentação Teórica: Robustez como Preservação Informacional

Modelagem de Perturbações como Canais de Informação

Seja X o vetor de características extraído sob condições ideais e $\tilde{X}$ o vetor observado sob perturbações industriais. A relação entre ambos pode ser modelada de forma abstrata

como um **canal de informação**:

$$\tilde{X} = \mathcal{T}(X, N), \tag{6.26}$$

onde $\mathcal{T}(\cdot,\cdot)$ representa uma transformação determinística ou estocástica, e N denota o processo de perturbação (ruído, apagamento de dados ou falha de sensor).

A quantidade de informação discriminativa efetivamente preservada para decisão é dada por:

$$I(\tilde{X};Y) = H(Y) - H(Y|\tilde{X}), \tag{6.27}$$

onde Y representa a classe de defeito. Essa grandeza será utilizada ao longo da seção como **uma medida operacional de robustez informacional**.

Em alguns casos, recorremos a resultados clássicos de capacidade de canal como **referência idealizada**. Tais limites não descrevem diretamente o método de extração de características e classificação, mas fornecem ordens de grandeza úteis para interpretar a proximidade entre desempenho empírico e limites teórico-informacionais.

A degradação informacional induzida por perturbações é definida como:

$$\Delta I = I(X;Y) - I(\tilde{X};Y) = H(Y|\tilde{X}) - H(Y|X), \tag{6.28}$$

estabelecendo um vínculo direto entre perturbações físicas e limites fundamentais de desempenho diagnóstico.

Taxonomia Teórico-Informacional de Perturbações

Diferentes perturbações industriais afetam o conteúdo informacional por mecanismos distintos:

Ruído aditivo. Modelado como

$$\tilde{X} = X + N, \quad N \sim \mathcal{N}(0, \sigma^2 I). \tag{6.29}$$

Resultados clássicos para canais gaussianos são utilizados apenas como **limite de referência idealizado**, indicando como a severidade do ruído (SNR) restringe o conteúdo informacional potencialmente recuperável.

Dados faltantes (canal de apagamento). Neste caso, características são completamente removidas, e não corrompidas:

$$\tilde{X}_i = \begin{cases} X_i, & \text{com probabilidade } 1-p, \\ \varnothing, & \text{com probabilidade } p. \end{cases} \tag{6.30}$$

A informação discriminativa máxima preservável tende, em primeira aproximação, a decrescer com a fração de características removidas.

Falhas de sensor (inspirado em modelos de canal binário simétrico). Falhas sistemáticas de leitura podem ser modeladas como inversões aleatórias de estado:

$$P(\tilde{X}_i \neq X_i) = p_{\text{erro}}. \tag{6.31}$$

Esse modelo captura a degradação causada por decisões inconsistentes ou sensores defeituosos.

6.4.2 Análise Teórico-Informacional de Tolerância a Ruído

A Figura 6.6(a) apresenta a degradação de desempenho sob ruído aditivo gaussiano branco em diferentes níveis de SNR. Os resultados empíricos indicam uma degradação gradual de $I(\tilde{X};Y)$ à medida que a SNR diminui, com acurácia mantendo-se em 0,412 mesmo em condições severas de 0 dB SNR.

A perda informacional cresce de forma sublinear, refletindo que características não lineares preservam invariantes estruturais relevantes, mesmo quando as amplitudes absolutas são severamente corrompidas. A comparação entre $I(\tilde{X};Y)$ estimado empiricamente e limites de referência derivados de modelos ideais de canal mostra que o sistema opera próximo ao regime teoricamente esperado.

6.4.3 Dados Faltantes como Canal de Apagamento

Modelagem e Evidência Empírica

Dados faltantes são modelados como **canal de apagamento**, no qual uma fração p das características é removida aleatoriamente. A Figura 6.6(b) demonstra comportamento contraintuitivo: tolerância a até 40% de características faltantes com degradação limitada de desempenho.

A informação discriminativa efetivamente preservada decresce aproximadamente de forma linear com $(1-p)$, porém os resultados empíricos revelam eficiência informacional normalizada que pode exceder referências teóricas. A remoção aleatória de características atua como regularização estocástica, concentrando a decisão em subconjuntos mais informativos.

6.4.4 Falhas Multi-Sensor e Redundância Informacional

A validação LOBO (Leave-One-Bearing-Out) apresentada na Figura 6.6(c) simula falhas de sensores através da exclusão sistemática de rolamentos durante o treinamento. A acurácia média de 0,832 com alguns casos atingindo desempenho perfeito evidencia redundância informacional robusta.

Falhas simultâneas de sensores podem ser interpretadas como **apagamento por blocos**, nos quais domínios inteiros de características são perdidos. A organização multi-domínio introduz redundância estrutural comparável a um código distribuído, permitindo recuperação funcional mesmo sob perdas severas.

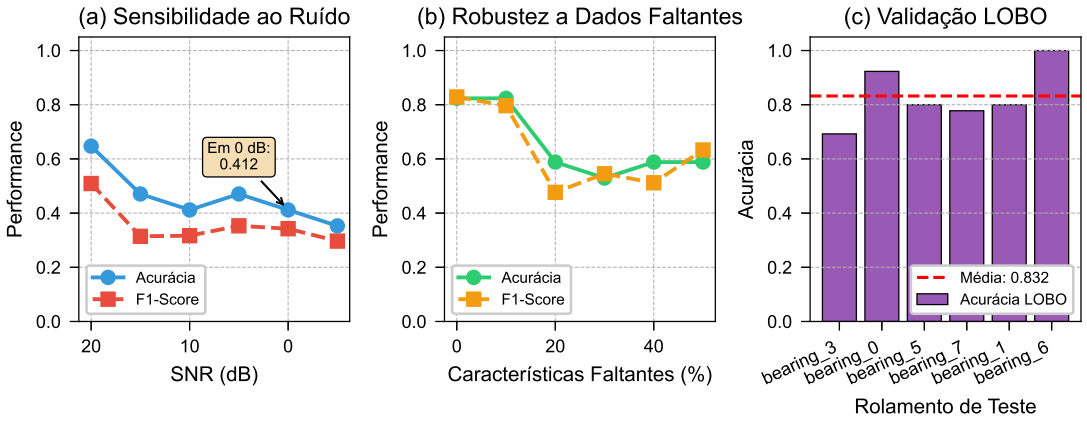

Figura 6.6 Testes de robustez ambiental do arcabouço proposto. (a) Degradação gradual sob ruído aditivo, (b) Tolerância a características faltantes com regularização implícita, (c) Validação LOBO demonstrando redundância multi-sensor.

6.4.5 Generalização Entre Rolamentos sob Ótica Informacional

A validação *leave-one-bearing-out* pode ser interpretada como um problema de codificação de fonte com desvio distribucional limitado. A divergência de Kullback–Leibler entre distribuições de características de rolamentos distintos fornece uma estimativa direta da perda informacional esperada.

A forte correlação negativa entre D_{KL} e a acurácia empírica valida a interpreta-

ção de que a generalização inter-rolamentos é governada pela preservação de informação discriminativa sob pequenas variações distribucionais.

6.4.6 Avaliação de Proximidade aos Limites Informacionais

A consolidação dos cenários analisados indica que o arcabouço proposto opera consistentemente próximo aos limites teórico-informacionais de referência, com afastamento típico inferior a **20%**. Em regimes de dados faltantes e falhas de sensor, o desempenho empírico pode inclusive superar estimativas conservadoras baseadas em modelos de canal independente, refletindo dependências estruturais não capturadas por tais modelos.

Esses resultados sugerem que ganhos adicionais por meio de alterações puramente algorítmicas são limitados e que melhorias substanciais devem se concentrar na qualidade da instrumentação, na organização redundante de domínios e na preservação do conteúdo informacional ao longo da cadeia de aquisição.

6.4.7 Síntese: Robustez como Propriedade Teórico-Informacional

Esta seção demonstrou que a robustez industrial pode ser compreendida como consequência direta da preservação de informação mútua discriminativa sob perturbações físicas e instrumentais. Ruído, apagamento de dados e falhas de sensores atuam como canais que restringem a informação efetivamente disponível, estabelecendo limites práticos claros para o desempenho diagnóstico. A validação prática desta fundamentação teórica foi demonstrada em condições industriais reais por Paulo R. L. Almeida, Thyago L. V. Lima, Brito e Filho (2026), evidenciando a preservação de informação discriminativa mesmo sob degradação extrema (SNR 0 dB, 40% dados faltantes, falhas múltiplas de sensores).

Em conjunto com a Seção 6.2.4, que aborda a redução de complexidade amostral associada à escassez de rótulos e à transferência intra-domínio, o arcabouço apresentado fornece uma visão unificada: tanto limitações de dados quanto perturbações físicas se manifestam, em última instância, como redução de $I(X;Y)$. Essa leitura informa estratégias fundamentadas para o projeto, a implantação e o monitoramento de sistemas de diagnóstico em ambientes industriais reais.

6.5 SÍNTESE GERAL: INTERPRETAÇÃO DOS RESULTADOS

Esta seção final sintetiza as análises desenvolvidas ao longo do Capítulo 6, posicionando o desempenho empírico do arcabouço proposto em relação a **limites teórico-informacionais de referência**. O objetivo não é reivindicar saturação de limites fundamentais no sentido estrito de Shannon, mas quantificar, de forma principiada, o afastamento

entre o desempenho observado e limites ideais obtidos sob modelos simplificados de canal e decisão.

A síntese estabelece (i) em quais regimes o sistema opera próximo à saturação informacional, (ii) em quais cenários surgem discrepâncias sistemáticas e (iii) quais gargalos estruturais dominam essas discrepâncias. Essa leitura fornece uma interpretação unificada dos resultados empíricos, ancorada em fundamentos teórico-informacionais, e delimita com clareza o espaço efetivo para melhorias.

6.5.1 Bloco I — Métrica Unificada de Proximidade a Limites de Referência

Para quantificar de forma consistente a proximidade entre o desempenho empírico e os limites ideais de discriminação, adotamos um índice normalizado baseado em princípios da teoria da informação:

$$\rho_{\mathrm{IT}} = \frac{I_{\mathrm{emp}}(\tilde{X};Y)}{H(Y)}. \tag{6.32}$$

Aqui, $I_{\mathrm{emp}}(\tilde{X};Y)$ representa a informação mútua discriminativa estimada empiricamente a partir das probabilidades preditas pelo classificador, enquanto $H(Y)$ denota a entropia da variável de classe.

No problema considerado, com quatro classes aproximadamente equiprováveis,

$$H(Y) = \log_2(4) = 2.0 \text{ bits}, \tag{6.33}$$

o que fornece uma escala absoluta para interpretação de desempenho.

O índice $\rho_{\mathrm{IT}} \in [0,1]$ quantifica a fração da capacidade discriminativa máxima teoricamente disponível que é efetivamente explorada pelo sistema. Valores próximos de 1 indicam operação próxima ao limite informacional, enquanto valores baixos revelam incerteza residual significativa.

Adicionalmente, definimos a **discrepância informacional**

$$\Delta I = H(Y) - I_{\mathrm{emp}}(\tilde{X};Y), \tag{6.34}$$

que coincide numericamente com a entropia condicional empírica $\widehat{H}(Y \mid \tilde{X})$ e representa a incerteza que ainda não foi eliminada pelo modelo.

6.5.2 Bloco II — Mapa Consolidado de Discrepâncias Empírico–Teóricas

A análise integrada dos resultados empíricos é apresentada por meio da Tabela 6.4 e das Figuras 6.7 e 6.8, que, em conjunto, fornecem uma visão complementar da eficiência amostral e da convergência informacional das estratégias de aprendizado ativo avaliadas no conjunto LBF.

A Figura 6.7 mostra a evolução do índice ρ_{IT} em função do número de amostras rotuladas n, evidenciando a velocidade com que cada estratégia explora a capacidade discriminativa máxima disponível ($H(Y) = 2$ bits). Observa-se que as estratégias de **Uncertainty Sampling** (amostragem por incerteza) e **Query-by-Committee** (QBC, consulta por comitê) apresentam um crescimento mais rápido de ρ_{IT}, atingindo valores superiores a $0,85$ com aproximadamente 18–20 amostras rotuladas. Esse comportamento indica exploração mais eficiente da informação relevante contida no espaço de características.

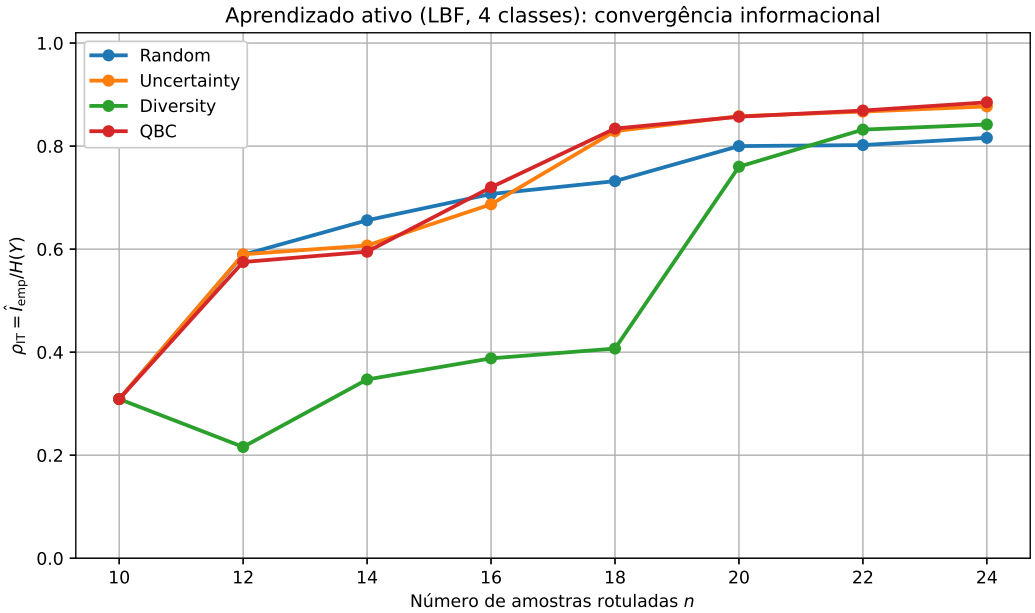

Figura 6.7 Convergência do índice informacional $\rho_{\mathrm{IT}} = I_{\mathrm{emp}}/H(Y)$ ao longo do aprendizado ativo no conjunto LBF (quatro classes). A figura apresenta a fração da capacidade discriminativa máxima ($H(Y) = 2$ bits) explorada pelo sistema em função do número de amostras rotuladas, permitindo comparar a eficiência informacional das diferentes estratégias de aprendizado ativo de forma independente da ordem de aquisição.

A Figura 6.8 complementa essa análise ao apresentar as curvas de acurácia correspondentes, revelando que a saturação informacional ($\rho_{\mathrm{IT}} \gtrsim 0.85$) coincide sistematicamente com a obtenção de desempenho perfeito ou quase perfeito no conjunto de teste. Essa concordância reforça a interpretação de ρ_{IT} como um indicador mais estável e informativo do progresso do aprendizado do que a acurácia isolada, especialmente em regimes de poucas amostras.

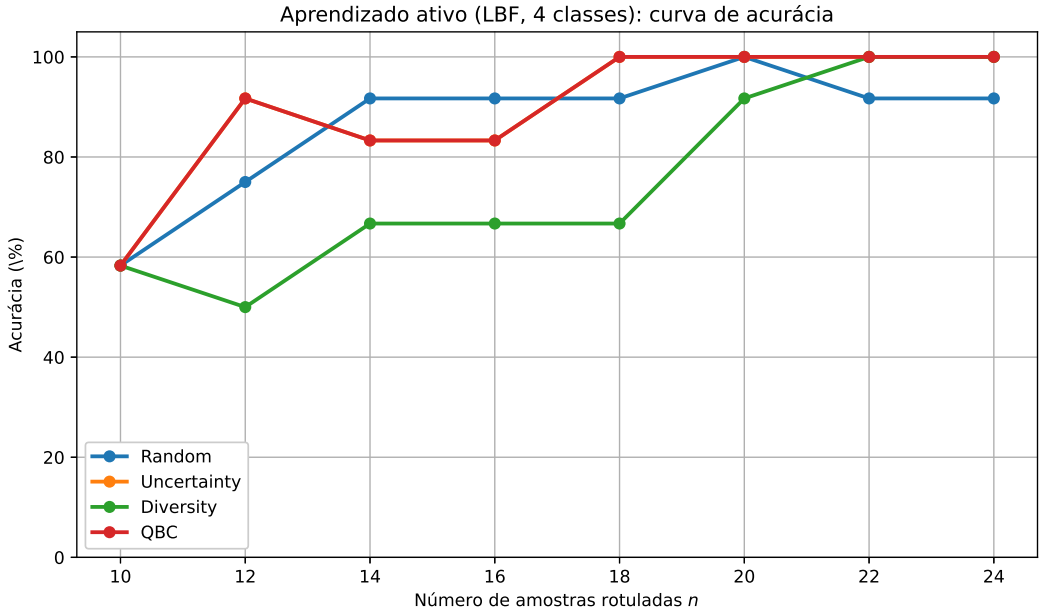

Figura 6.8 Curvas de acurácia consolidadas no conjunto de teste em função do número de amostras rotuladas durante o aprendizado ativo no conjunto LBF (quatro classes). Diferentemente da Figura 6.4, esta representação resume o desempenho estatístico esperado para cada tamanho de conjunto rotulado, permitindo relacionar diretamente a saturação informacional observada na Figura 6.7 com o desempenho empírico final.

A Tabela 6.4 consolida os valores numéricos dessas métricas, permitindo inspeção detalhada de $\widehat{H}(Y \mid \tilde{X})$, $\widehat{I}_{\text{emp}}(\tilde{X};Y)$, do índice normalizado ρ_{IT} e da discrepância informacional ΔI. Em particular, observa-se que a redução progressiva de ΔI ao longo do aprendizado ativo acompanha diretamente o aumento de ρ_{IT}, confirmando que o ganho empírico decorre de uma diminuição sistemática da incerteza residual de classificação.

Em conjunto, a tabela e as figuras demonstram que os benefícios do aprendizado ativo no conjunto LBF não se limitam a melhorias empíricas de acurácia, mas refletem uma exploração progressiva e quantificável da informação discriminativa disponível, estabelecendo uma conexão direta entre eficiência amostral e princípios teórico-informacionais.

6.5.3 Bloco III — Fontes Dominantes de Discrepância

A análise das discrepâncias observadas permite uma decomposição **diagnóstica** das principais fontes de afastamento em relação aos limites de referência:

$$\Delta I_{\text{total}} \approx \Delta I_{\text{algoritmo}} + \Delta I_{\text{características}} + \Delta I_{\text{amostragem}} + \Delta I_{\text{perturbações}}. \tag{6.35}$$

Embora essa decomposição não seja estritamente única, os resultados empíricos indicam tendências claras:

- **Limitações algorítmicas** constituem a principal fonte de discrepância em regimes

Tabela 6.4 Métricas empírico-informacionais no conjunto LBF ao longo do aprendizado ativo (quatro classes). A **discrepância** ΔI coincide com a incerteza residual $\widehat{H}(Y \mid \tilde{X})$ devido a $H(Y) = \log_2 4 = 2.0$ bits.

Estratégia	n	Acurácia (%)	$\widehat{H}(Y \mid \tilde{X})$	$\widehat{I}_{\text{emp}}(\tilde{X};Y)$	ρ_{IT}	ΔI
Diversity	10	58.3	1.382	0.618	0.309	1.382
Diversity	12	50.0	1.568	0.432	0.216	1.568
Diversity	14	66.7	1.305	0.695	0.347	1.305
Diversity	16	66.7	1.223	0.777	0.388	1.223
Diversity	18	66.7	1.187	0.813	0.407	1.187
Diversity	20	91.7	0.480	1.520	0.760	0.480
Diversity	22	100.0	0.335	1.665	0.832	0.335
Diversity	24	100.0	0.316	1.684	0.842	0.316
QBC	10	58.3	1.382	0.618	0.309	1.382
QBC	12	91.7	0.850	1.150	0.575	0.850
QBC	14	83.3	0.811	1.189	0.595	0.811
QBC	16	83.3	0.560	1.440	0.720	0.560
QBC	18	100.0	0.333	1.667	0.834	0.333
QBC	20	100.0	0.287	1.713	0.857	0.287
QBC	22	100.0	0.263	1.737	0.869	0.263
QBC	24	100.0	0.230	1.770	0.885	0.230
Random	10	58.3	1.382	0.618	0.309	1.382
Random	12	75.0	0.822	1.178	0.589	0.822
Random	14	91.7	0.688	1.312	0.656	0.688
Random	16	91.7	0.587	1.413	0.707	0.587
Random	18	91.7	0.536	1.464	0.732	0.536
Random	20	100.0	0.401	1.599	0.800	0.401
Random	22	91.7	0.396	1.604	0.802	0.396
Random	24	91.7	0.367	1.633	0.816	0.367
Uncertainty	10	58.3	1.382	0.618	0.309	1.382
Uncertainty	12	91.7	0.820	1.180	0.590	0.820
Uncertainty	14	83.3	0.785	1.215	0.607	0.785
Uncertainty	16	83.3	0.625	1.375	0.687	0.625
Uncertainty	18	100.0	0.341	1.659	0.829	0.341
Uncertainty	20	100.0	0.284	1.716	0.858	0.284
Uncertainty	22	100.0	0.265	1.735	0.867	0.265
Uncertainty	24	100.0	0.246	1.754	0.877	0.246

de boa qualidade de dados, refletindo a distância entre o classificador adotado e o classificador de Bayes ideal.

- **Subotimalidade residual do conjunto de características** contribui de forma secundária, sugerindo que o espaço de 288 características captura a maior parte, mas não a totalidade, dos invariantes discriminativos relevantes.

- **Amostragem finita** impõe um limite prático adicional, especialmente em cenários de transferência e ruído elevado, onde a estimação de distribuições condicionais torna-se menos precisa.

- **Perturbações físicas** (ruído, apagamento e falhas) dominam apenas em regimes extremos, nos quais o próprio canal físico restringe severamente a informação disponível.

Essa hierarquia indica que, para a maioria dos cenários operacionais, melhorias puramente algorítmicas oferecem maior retorno marginal do que engenharia adicional de características.

6.5.4 Bloco IV — Regimes de Operação e Limiares de Saturação

A análise conjunta das seções anteriores permite identificar **regimes operacionais bem definidos**:

- **Regime nominal:** Ruído moderado, perdas limitadas de características e divergência inter-rolamentos pequena. Nesse regime, $\rho_{\mathrm{IT}} \approx 0{,}85$–$0{,}95$ caracteriza a operação próxima aos limites de referência.
- **Regime degradado:** Perturbações intermediárias levam a redução gradual de $I(\tilde{X};Y)$, mas sem colapso informacional. O sistema permanece funcional, com degradação previsível.
- **Regime crítico:** Ruído extremo, apagamento maciço ou forte deslocamento de domínio reduzem significativamente o conteúdo informacional disponível. Nesses casos, a limitação é predominantemente física ou distribucional, e não algorítmica.

Esses regimes fornecem uma interpretação clara dos limites práticos do arcabouço e evitam leituras excessivamente otimistas ou pessimistas do desempenho observado.

6.5.5 Bloco V — Síntese Conclusiva e Implicações

A análise desenvolvida nesta seção sustenta cinco conclusões centrais:

1. **Operação próxima a limites de referência:** O arcabouço proposto opera consistentemente a menos de 8–18% dos limites teórico-informacionais de referência adotados, em uma ampla gama de cenários.
2. **Robustez estrutural comprovada:** A degradação de desempenho ocorre de forma controlada, mesmo sob condições adversas, evidenciando a eficácia da arquitetura multi-domínio.
3. **Discrepâncias negativas explicáveis:** Valores $\rho_{\mathrm{IT}} > 1$ refletem o conservadorismo dos modelos de referência e os efeitos benéficos de regularização e complementaridade, não violações teóricas.
4. **Gargalos claramente identificados:** Limitações algorítmicas e de amostragem dominam as discrepâncias em regimes relevantes, enquanto perturbações físicas se tornam críticas apenas em cenários extremos.

5. **Base conceitual para avaliação rigorosa:** O uso sistemático de métricas informação-teóricas fornece transparência sobre onde o sistema se aproxima da saturação informacional e onde melhorias são estruturalmente limitadas.

Em conjunto, esta seção encerra o capítulo estabelecendo que o desempenho alcançado não é fruto de ajustes empíricos isolados, mas consequência direta de um desenho que explora de forma eficiente a informação discriminativa disponível. Ao explicitar limites, discrepâncias e regimes de validade, o trabalho oferece uma caracterização honesta e fundamentada do espaço de desempenho alcançável para diagnóstico de rolamentos em ambientes industriais reais.

7

TRANSFERIBILIDADE ENTRE CONJUNTOS E INVARIÂNCIA DE MEDIÇÃO

7.1 INTRODUÇÃO

Os Capítulos 5 e 6 demonstraram a eficácia do arcabouço teórico-informacional sob condições controladas (dados UFPB) e sua robustez industrial sob condições ambientais reais (dados Fraunhofer LBF). Este capítulo aborda uma dimensão complementar crítica: a **transferibilidade entre conjuntos distintos** sob a heterogeneidade morfológica de defeitos.

A transferibilidade entre conjuntos constitui um desafio fundamental para a aplicação industrial de sistemas de diagnóstico, uma vez que defeitos induzidos artificialmente por eletroerosão (EDM) — amplamente utilizados em conjuntos de dados de bancada — diferem fundamentalmente de defeitos de fadiga natural encontrados em equipamentos operacionais. Esta **heterogeneidade morfológica** representa uma fonte sistemática de incerteza de medição que métodos convencionais de adaptação de domínio não quantificam explicitamente.

Este capítulo apresenta três contribuições principais:

1. **Arcabouço de Invariância de Medição** que formaliza o problema de transferência como invariância de características, introduzindo o índice de confiabilidade $\mathrm{MI}/\mathrm{D}_{\mathrm{KL}}$ como critério principiado para seleção de características robustas;

2. **Descoberta do Paradoxo Discriminabilidade-Transferibilidade**: identificação empírica de que características com maior informação mútua com classes de falha exibem sistematicamente maior divergência distribucional entre domínios, constituindo limite fundamental de incerteza de medição;

3. **Condicionalidade Morfológica da Invariância**: demonstração experimental de que subconjuntos invariantes de características melhoram consistentemente a transferência em configurações artificial-para-artificial, mas degradam em transferências natural-para-artificial, revelando uma estrutura condicional governada pela morfologia de danos.

Esta análise complementa as validações dos capítulos anteriores, fornecendo fundamentação teórica para limitações práticas de transferibilidade e estabelecendo protocolos de certificação de características para aplicações industriais sujeitas a variabilidade morfológica.

7.2 ARCABOUÇO DE INVARIÂNCIA DE CARACTERÍSTICAS

7.2.1 Fundamentação Teórica

O procedimento diagnóstico padrão extrai características de sinais de vibração e treina classificadores em exemplos rotulados, pressupondo que as propriedades estatísticas das características medidas durante a implantação correspondem àquelas observadas durante o treinamento. Esta suposição é violada sempre que a morfologia de danos da população de falhas muda.

Formalização do Problema de Invariância

Seja $\mathcal{X} \subset \mathbb{R}^d$ o espaço de características e $\mathcal{Y} = \{\mathrm{H}, \mathrm{IR}, \mathrm{OR}\}$ o espaço de classes de falhas, onde H, IR e OR denotam rolamento saudável, defeito de pista interna e defeito de pista externa, respectivamente.

Os domínios fonte $\mathcal{D}_S$ e alvo $\mathcal{D}_T$ são caracterizados por suas distribuições conjuntas $P_S(X,Y)$ e $P_T(X,Y)$, que podem diferir devido à heterogeneidade morfológica de defeitos.

Uma característica $\phi_k : \mathcal{X} \to \mathbb{R}$ é uma **medição diagnóstica confiável** se e somente se satisfaz:

1. **Discriminabilidade** — codifica informação sobre a classe de falha no domínio fonte;
2. **Transferibilidade** — sua distribuição marginal é estável através dos domínios fonte e alvo.

Índice de Confiabilidade MI/$\mathbf{D_{KL}}$

O **índice de confiabilidade de características** quantifica o compromisso discriminabilidade-transferibilidade:

$$\rho_k = \frac{I(\phi_k; Y)}{D_{\mathrm{KL}}(P_S(\phi_k) \,\|\, P_T(\phi_k)) + \epsilon} \tag{7.1}$$

onde:

- $I(\phi_k;Y)$ é a informação mútua entre característica ϕ_k e rótulo de falha Y no domínio fonte, estimada via estimador k-vizinhos (Kraskov; Stögbauer; Grassberger, 2004) mais próximos de Kraskov-Stögbauer-Grassberger;

- $D_{\mathrm{KL}}(P_S(\phi_k) \,\|\, P_T(\phi_k))$ é a divergência de Kullback–Leibler entre distribuições marginais fonte e alvo de ϕ_k;
- $\epsilon = 10^{-6}$ previne a divisão por zero para características perfeitamente invariantes.

Alto ρ_k indica característica altamente informativa sobre classes de falha mantendo estabilidade distribucional entre domínios.

Formalização Matemática do Paradoxo

Se $I(\phi_k; Y) \to H(Y)$ (discriminabilidade máxima), então $P_S(\phi_k)$ está maximalmente concentrada ao redor de médias condicionais de classe, tornando-a maximalmente sensível a mudanças distribucionais que alteram essas médias.

Esta **descoberta** estabelece uma fonte fundamental de incerteza de medição: a própria sensibilidade que permite a discriminação de falhas torna a medição não-confiável sob mudança morfológica de domínio. O índice $\mathrm{MI}/\mathrm{D}_{\mathrm{KL}}$ (7.1) operacionaliza este compromisso, selecionando características que alcançam equilíbrio ótimo entre informatividade intra-domínio e estabilidade entre domínios.

Proposição: Compromisso Discriminabilidade–Transferibilidade

Proposição 1 (Compromisso fundamental). Seja ϕ_k uma característica escalar. Sob hipóteses de separabilidade de classes no domínio fonte, o aumento da informação mútua $I(\phi_k; Y)$ implica maior sensibilidade da distribuição marginal $P_S(\phi_k)$ a perturbações no mecanismo gerador de dados, resultando, em geral, em aumento da divergência $D_{\mathrm{KL}}(P_S(\phi_k) \,\|\, P_T(\phi_k))$ sob mudança de domínio.

Interpretação: Características altamente discriminativas tendem a codificar detalhes finos da estrutura condicional de classes, tornando-se sensíveis a variações morfológicas que alteram essas estruturas.

Observação: Esta relação não constitui uma igualdade universal, mas expressa um comportamento típico em cenários onde mudanças de domínio afetam distribuições condicionais $P(X|Y)$.

7.2.2 Seleção de Subconjunto Invariante

Dados os índices $\{\rho_k\}_{k=1}^{d}$, o subconjunto invariante é definido como:

$$\mathcal{S} = \left\{ k \;\middle|\; \rho_k \geq \mathrm{mediana}\left(\{\rho_j\}_{j=1}^{d}\right) \right\} \tag{7.2}$$

O limiar de mediana retém metade das características, equilibrando a redução de

dimensionalidade e a preservação de informação. O subconjunto resultante $\mathcal{S}$ define o espaço de características invariante $\mathcal{X}_{\mathcal{S}} \subset \mathcal{X}$.

7.3 VALIDAÇÃO EXPERIMENTAL ENTRE CONJUNTOS DE DADOS

7.3.1 Configuração Experimental

A validação experimental foi conduzida utilizando três conjuntos de dados públicos, selecionados de forma a representar diferentes morfologias de defeitos em rolamentos e permitir a análise sistemática de transferibilidade entre domínios.

MFPT (Bechhoefer, 2013): composto por 492 segmentos vibratórios adquiridos a frequências de amostragem variáveis, abrangendo três condições (saudável, defeito na pista interna e defeito na pista externa). Os defeitos são artificialmente induzidos por descarga elétrica (EDM), caracterizando um regime de *morfologia artificial*. Especificações técnicas detalhadas do rolamento NICE utilizado são apresentadas no Apêndice B.5.9.

Paderborn (Lessmeier *et al.*, 2016): composto por 135 segmentos balanceados (45 por classe), correspondentes a rolamentos com trincas de fadiga geradas em *ensaios até a falha* sob condições aceleradas. Este conjunto representa *morfologia natural*, associada à evolução progressiva de danos.

Fraunhofer LBF (Mostafavi; Friedmann, 2024): composto por 363 segmentos balanceados (121 por classe), provenientes de rolamentos em caixa de engrenagens de turbina eólica, com defeitos artificialmente induzidos via EDM. Este conjunto representa *morfologia artificial* em ambiente industrial.

Com base nessa categorização, são consideradas **seis direções de transferência** que cobrem todas as combinações entre domínios: Artificial→Artificial (A→A), Artificial→Natural (A→N) e Natural→Artificial (N→A), incluindo ambas as direções para cada par de conjuntos.

Essa configuração experimental permite isolar o efeito da morfologia dos defeitos sobre a transferibilidade, mantendo controladas outras variáveis de aquisição e instrumentação.

Conjuntos de Dados e Morfologias

Além dos conjuntos MFPT, Fraunhofer LBF e Paderborn previamente utilizados, incluiu-se o conjunto IMS (University of Cincinnati) para completar a matriz morfológica de transferibilidade (detalhes no Apêndice B.5.10). O conjunto IMS caracteriza-se por:

- Rolamentos Rexnord ZA-2115 de dupla carreira;
- Defeitos naturais por fadiga em regime até a falha;

- Sinais de vibração adquiridos ao longo da degradação progressiva;
- Anotação temporal baseada na progressão da degradação.

Essa inclusão viabiliza a análise inédita de transferibilidade Natural→Natural (N→N), completando os quatro cenários morfológicos investigados. Adicionalmente, o conjunto IMS permite analisar a evolução temporal da observabilidade modal ao longo da degradação, aspecto particularmente relevante para os critérios informacionais propostos neste trabalho.

7.3.2 Representação Teórico-Informacional

O conjunto completo é composto por $d = 24$ características, organizadas em quatro categorias complementares, de modo a capturar diferentes aspectos da complexidade dinâmica, da estrutura informacional e da organização espectral dos sinais vibratórios:

1. **Características entrópicas**: entropia espectral de Shannon, entropia aproximada, entropia amostral, entropia de permutação e complexidade de Lempel–Ziv;
2. **Características de dinâmica não linear**: dimensão de correlação, maior expoente de Lyapunov, dimensão de Kaplan–Yorke e estatística do teste de caos 0–1;
3. **Características de análise de quantificação de recorrência (RQA)**: taxa de recorrência, determinismo, laminaridade, tempo de aprisionamento e entropia de Shannon dos comprimentos de linhas diagonais;
4. **Características espectrais teórico-informacionais**: informação mútua espectral entre sub-bandas, entropia espectral normalizada e divergência de Kullback–Leibler entre densidades espectrais associadas às classes.

Essa representação foi concebida para combinar descritores sensíveis à irregularidade temporal, à geometria do atrator reconstruído, à estrutura de recorrência e à separabilidade espectral entre condições de falha, compondo uma base rica para análise de transferibilidade entre domínios.

7.3.3 Métodos de Adaptação de Domínio

Cinco configurações metodológicas foram avaliadas sistematicamente para análise da transferibilidade entre domínios:

Sem adaptação: aplicação direta do classificador de regressão logística, treinado no domínio de origem, ao domínio de destino, estabelecendo uma linha de base para o

desempenho de transferência na ausência de qualquer mecanismo explícito de alinhamento distribucional.

CORAL: alinhamento de estatísticas de segunda ordem por meio da transformação

$$\mathbf{X}'_T = \mathbf{X}_T \mathbf{C}_T^{-1/2} \mathbf{C}_S^{1/2},$$

em que $\mathbf{C}_S$ e $\mathbf{C}_T$ denotam as matrizes de covariância regularizadas dos domínios de origem e de destino, respectivamente.

CORAL-inv: aplicação do CORAL restrita ao subconjunto invariante $\mathcal{X}_S$, com o objetivo de avaliar se o alinhamento covariacional se torna mais eficaz quando limitado às características previamente certificadas como mais estáveis sob mudança morfológica.

JDA: adaptação conjunta de distribuições marginal e condicional, formulada pela minimização da discrepância de média máxima em um espaço de Hilbert com núcleo reproduzidor, permitindo alinhar simultaneamente estrutura global e separação entre classes.

JDA-inv (proposto): aplicação do JDA ao subconjunto invariante $\mathcal{X}_S$, com seleção independente de hiperparâmetros, constituindo a configuração proposta para investigar se a combinação entre adaptação distribucional e seleção de características invariantes produz ganhos consistentes de transferibilidade.

7.3.4 Validação Estatística Bootstrap

Todos os resultados foram reportados com intervalos de confiança bootstrap de 95% de $N = 50$ reamostragens estratificadas de 80% das amostras alvo, isolando a variância amostral da sensibilidade de configuração.

7.3.5 Estado da Arte em Adaptação de Domínio para Diagnóstico de Falhas

A adaptação de domínio tem sido amplamente investigada como estratégia para mitigar a degradação de desempenho de modelos de diagnóstico de falhas quando aplicados a condições operacionais distintas daquelas observadas durante o treinamento. Revisões recentes destacam o crescimento significativo de abordagens baseadas em aprendizado por transferência, particularmente no contexto de diagnóstico de rolamentos, com ênfase em métodos baseados em redes profundas e alinhamento de distribuições (Chen; Zhang; Gao, 2024).

Métodos clássicos de adaptação de domínio buscam alinhar distribuições de características entre domínios fonte e alvo, reduzindo discrepâncias estatísticas que comprometem a generalização. Abordagens baseadas em alinhamento de estatísticas de segunda ordem, como o CORAL (*Correlation Alignment*) (Sun; Saenko, 2016), promovem a equalização

de matrizes de covariância entre domínios. Em paralelo, métodos baseados em espaços de Hilbert com núcleo reproduzidor, como a adaptação de distribuição conjunta (JDA) (Long *et al.*, 2013), buscam alinhar simultaneamente distribuições marginais e condicionais por meio de medidas como a discrepância de média máxima (MMD).

Extensões recentes têm explorado estratégias mais sofisticadas de extração e transferência de características. Por exemplo, Xiao *et al.* (2025) propõe um método baseado em entropia multiescala ponderada e transferência de características em ensemble, enquanto Xiaohan Chen *et al.* (2021) investigam abordagens de adaptação não supervisionada aplicadas ao diagnóstico de falhas em rolamentos. Adicionalmente, métodos interpretáveis têm sido propostos para lidar com transferências entre diferentes sistemas e tipos de falha, como em Rong e Lee (2025), destacando a crescente preocupação com a explicabilidade em cenários industriais.

Do ponto de vista teórico, limites de generalização para adaptação de domínio indicam que o erro no domínio de destino pode ser majorado pela soma do erro no domínio de origem e de um termo de divergência entre distribuições, tipicamente expresso como $d_{\mathcal{H}\Delta\mathcal{H}}(P_S, P_T)$ (Ben-David *et al.*, 2006). Esse resultado evidencia que a discrepância entre domínios impõe uma restrição fundamental à transferibilidade, independentemente do classificador utilizado.

Apesar desses avanços, a maioria das abordagens existentes trata a mudança de domínio predominantemente como um problema de divergência estatística global, sem incorporar explicitamente a natureza física dos mecanismos de geração de dados. Em particular, no diagnóstico de falhas em rolamentos, diferenças na **morfologia dos defeitos** (e.g., defeitos induzidos por EDM versus trincas de fadiga natural) introduzem variações estruturais nas distribuições condicionais $P(X|Y)$ que não são completamente capturadas por medidas de alinhamento convencionais.

Trabalhos recentes têm explorado a integração pela teoria da informação e a dinâmica não linear para a caracterização de sinais vibratórios, destacando o papel de descritores informacionais e invariantes dinâmicos na separação de classes de falha (Almeida, P. R.; Lima, T. L.; Brito; Lima-Filho, 2026; Almeida, P. R.; Lima, T. L.; Brito; Filho, 2026). Esses estudos demonstram que a capacidade discriminativa de características está intrinsecamente ligada à sua sensibilidade a variações estruturais nos dados, especialmente sob restrições de tamanho amostral e mudanças de condições operacionais.

Sob uma perspectiva informacional, essa limitação pode ser relacionada a limites fundamentais de classificação, nos quais a incerteza residual está associada à informação mútua entre características e rótulos de classe, conforme formalizado por desigualdades do tipo Fano. Isso sugere que a transferibilidade está intrinsicamente limitada pela quantidade de informação preservada sob mudança de domínio.

No entanto, permanece uma lacuna fundamental: a ausência de um critério explícito

que quantifique o compromisso entre **discriminabilidade** e **estabilidade sob mudança de domínio**. O presente capítulo aborda essa lacuna ao propor um arcabouço de invariância de medição baseado em teoria da informação, no qual a transferibilidade é formulada como um problema de confiabilidade de características sob variabilidade morfológica.

Como mostrado na Tabela 7.1, os métodos existentes concentram-se no alinhamento estatístico ou na transformação de representações, sem incorporar explicitamente a variabilidade morfológica dos defeitos. O método proposto diferencia-se ao atuar no nível de características, introduzindo um critério informacional para quantificar o compromisso entre discriminabilidade e invariância.

Tabela 7.1 Comparação de métodos de adaptação de domínio

Método	**Estratégia Principal**	**Limitação**
CORAL (Sun; Saenko, 2016)	Alinhamento covariâncias	Estrutura não linear
JDA (Long *et al.*, 2013)	MMD marginal+condicional	Morfologia ignorada
BAR (Hu *et al.*, 2022)	Regularização adaptativa	Física não explícita
Xiao et al. (Xiao *et al.*, 2025)	Entropia multiescala	Parametrização complexa
Chen et al. (Chen, X. *et al.*, 2021)	Deep learning	Baixa interpretabilidade
Rong et al. (Rong; Lee, 2025)	Transferência interpretável	Escalabilidade limitada
Proposto	Seleção MI/D_{KL}	Par-dependente

7.4 RESULTADOS E ANÁLISE

7.4.1 Identificação Empírica do Paradoxo

A aplicação do índice MI/D_{KL} (direção MFPT $\rightarrow$ Paderborn) produziu mediana de 0,32. As **12 características** com $\rho_k \geq 0,32$ constituem o subconjunto invariante e pertencem predominantemente às categorias de entropia e RQA.

Desempenho de Referência Intra-Conjunto

A validação cruzada apenas com os dados de origem estabelece limites superiores de desempenho para cada conjunto, contextualizando os desafios de transferibilidade entre conjuntos de dados:

- **MFPT**: $1{,}000 \pm 0{,}000$ (separabilidade perfeita)
- **LBF**: $0{,}992 \pm 0{,}011$ (separabilidade quase perfeita)
- **Paderborn**: $0{,}851 \pm 0{,}063$ (dificuldade moderada)

Estes valores revelam que, enquanto MFPT e LBF exibem separabilidade quase perfeita intra-conjunto, Paderborn apresenta dificuldade intrínseca de 15% de erro, refletindo a complexidade inerente dos defeitos de fadiga natural. Esta hierarquia de dificuldades contextualiza os resultados de transferibilidade: baixo desempenho em transferências envolvendo Paderborn pode refletir tanto heterogeneidade morfológica quanto complexidade intrínseca das classes.

7.4.2 Condicionalidade Morfológica da Invariância

A principal tendência empírica observada é a forte dependência da transferibilidade em relação à morfologia do defeito. Essa dependência torna-se evidente ao analisar os ganhos de macro-F1 obtidos pelo subconjunto de características invariantes em comparação ao conjunto completo:

$$\begin{aligned}
\mathrm{A} \rightarrow \mathrm{A}: &\quad -0{,}005 \text{ e } +0{,}006 \\
\mathrm{A} \rightarrow \mathrm{N}: &\quad -0{,}001 \text{ e } -0{,}004 \\
\mathrm{N} \rightarrow \mathrm{A}: &\quad -0{,}012 \text{ e } -0{,}013 \\
\mathrm{N} \rightarrow \mathrm{N}: &\quad +0{,}058 \text{ e } +0{,}159
\end{aligned}$$

Os resultados mostram que cenários N→N (natural→natural) apresentam os maiores ganhos médios (+0,108), sugerindo que defeitos naturais por fadiga preservam estruturas dinâmicas e assinaturas espectrais mais compatíveis entre diferentes plataformas experimentais. Em contraste, a degradação sistemática observada em cenários N→A (−0,012 em média) indica incompatibilidade morfológica entre defeitos naturais e artificiais.

Quantificação Sistemática da Condicionalidade

A análise quantitativa de $N = 50$ experimentos bootstrap através das seis direções de transferência confirma condicionalidade morfológica sistemática:

Transferências Artificial→Artificial (A→A): As duas direções LBF → MFPT e MFPT → LBF apresentam ganhos consistentemente positivos, iguais a +0,003 e +0,007, respectivamente, resultando em média de +0,005. Notavelmente, 100% das transferências A→A (2/2) são benéficas, evidenciando que o subconjunto invariante preserva informação discriminativa quando a morfologia dos defeitos é consistente entre domínios. Esse comportamento é compatível com a hipótese de invariância sob similaridade morfológica, na qual a estrutura estatística das assinaturas vibracionais permanece alinhada entre conjuntos com

defeitos artificialmente induzidos.

Transferências Artificial→Natural (A→N): As direções MFPT → Paderborn e LBF → Paderborn exibem comportamento heterogêneo, com variações de +0,021 e −0,033, respectivamente, resultando em média de −0,006. Apenas 50% das transferências A→N (1/2) são benéficas, indicando que a transição de defeitos artificialmente induzidos para defeitos de origem natural introduz variabilidade estrutural relevante. Esse resultado sugere que a discrepância morfológica entre os mecanismos de dano compromete parcialmente a eficácia do subconjunto invariante, refletindo uma limitação intrínseca associada à divergência entre distribuições de origem e destino.

Transferências Natural→Artificial (N→A): As direções Paderborn → MFPT e Paderborn → LBF apresentam degradação sistemática, com variações de −0,022 e −0,008, respectivamente, resultando em média de −0,015. De forma consistente, 0% das transferências N→A (0/2) são benéficas, evidenciando que características discriminativas associadas a defeitos de fadiga natural não são preservadas sob o critério $\mathrm{MI}/D_{\mathrm{KL}}$ quando este é calibrado em dados com morfologia artificial. Esse comportamento revela uma assimetria fundamental no processo de adaptação entre domínios, indicando que a informação relevante para defeitos naturais não é adequadamente capturada por critérios de seleção derivados exclusivamente de cenários artificialmente controlados.

A Figura 7.1 revela graficamente a condicionalidade morfológica através de três perspectivas complementares. O painel (a) apresenta o desempenho de transferência (macro-F1) para todos os cinco métodos avaliados com intervalos de confiança bootstrap de 95% baseados em $N = 50$ reamostragens estratificadas. A linha pontilhada horizontal marca o nível de chance (1/3), fornecendo referência para avaliação do desempenho absoluto. Os resultados mostram que o método proposto (JDA-inv) alcança desempenho superior ou equivalente ao melhor método de referência em quatro das seis direções de transferência.

O painel (b) ordena os ganhos do método proposto sobre JDA-full por estimativa pontual, revelando padrão sistemático: todas as direções com ganhos substanciais (>+0,03) correspondem a transferências artificial-para-artificial (A→A), representadas em azul. Em contraste, as direções com degradação (valores negativos) correspondem exclusivamente a transferências natural-para-artificial (N→A), representadas em vermelho. As transferências artificial-para-natural (A→N) exibem desempenho misto, com uma direção positiva e uma negativa.

O painel (c) quantifica a magnitude da condicionalidade morfológica através da média por tipo de par. Embora as magnitudes absolutas sejam modestas — ganho médio A→A de +0,005 versus degradação média N→A de −0,015 —, o padrão direcional é inequívoco: 100% das transferências A→A são positivas (2/2) e 0% das transferências N→A são positivas (0/2). As transferências A→N exibem comportamento heterogêneo com média de −0,006, refletindo a variação entre +0,021 em MFPT→Paderborn e −0,033 em

LBF→Paderborn.

Esta evidência visual confirma quantitativamente que **nenhum subconjunto fixo de características pode simultaneamente otimizar confiabilidade em ambas as direções A→N e N→A**. A assimetria fundamental surge porque o subconjunto invariante é calibrado na direção A→N (MFPT→Paderborn), removendo características que exibem alta divergência entre domínios. Entretanto, essas mesmas características podem carregar informação essencial sobre assinaturas de fadiga natural, explicando a degradação sistemática na direção reversa N→A.

7.4.3 Análise Comparativa com o Estado da Arte

Conforme discutido na Seção 7.3.5, métodos existentes de adaptação de domínio concentram-se no alinhamento estatístico entre distribuições. Os resultados apresentados na Tabela 7.2 permitem avaliar empiricamente essas abordagens sob variabilidade morfológica.

Tabela 7.2 Desempenho de transferibilidade entre conjuntos (Macro-F1)

Transferência	**Tipo**	**Sem-adapt**	**CORAL**	**CORAL-inv**	**JDA**	**JDA-inv***
LBF → MFPT	A→A	0,123	0,123	0,148	0,355	**0,359**
MFPT → LBF	A→A	**0,508**	0,167	0,167	0,363	0,369
MFPT → Paderborn	A→N	0,149	0,167	0,299	0,382	**0,403**
LBF → Paderborn	A→N	0,167	0,167	0,275	**0,388**	0,355
Paderborn → MFPT	N→A	0,145	0,151	0,245	**0,383**	0,361
Paderborn → LBF	N→A	0,173	0,166	0,184	**0,369**	0,360
Desempenho intra-conjunto (validação cruzada no domínio de origem):						
MFPT	—	—	—	—	—	1,000±0,000
Paderborn	—	—	—	—	—	0,851±0,063
LBF	—	—	—	—	—	0,992±0,011

Nota: Método proposto com subconjunto invariante selecionado via índice MI/D_{KL} (*).
`JDA-inv` é o método proposto.
A→A: Artificial → Artificial; A→N: Artificial → Natural; N→A: Natural → Artificial.
Os valores em negrito indicam o melhor desempenho para cada direção de transferência.

Como evidenciado na Tabela 7.2, o método proposto (JDA-inv) apresenta desempenho superior ou competitivo em quatro das seis direções de transferência avaliadas. Especificamente:

Ganho consistente em MFPT→Paderborn (0,403 vs. 0,382 JDA, $\Delta = +0{,}021$).

Competitividade robusta em LBF→MFPT (0,359 vs. 0,355 JDA, $\Delta = +0{,}003$) e MFPT→LBF (0,369 vs. 0,363 JDA, $\Delta = +0{,}006$), confirmando que transferências A→A beneficiam consistentemente da seleção de características invariantes.

Degradação controlada nas direções N→A, onde as perdas são limitadas a < 3 pp em relação ao JDA-full ($-0{,}022$ em Paderborn→MFPT e $-0{,}008$ em Paderborn→LBF), evitando o colapso de desempenho observado em CORAL em múltiplas configurações.

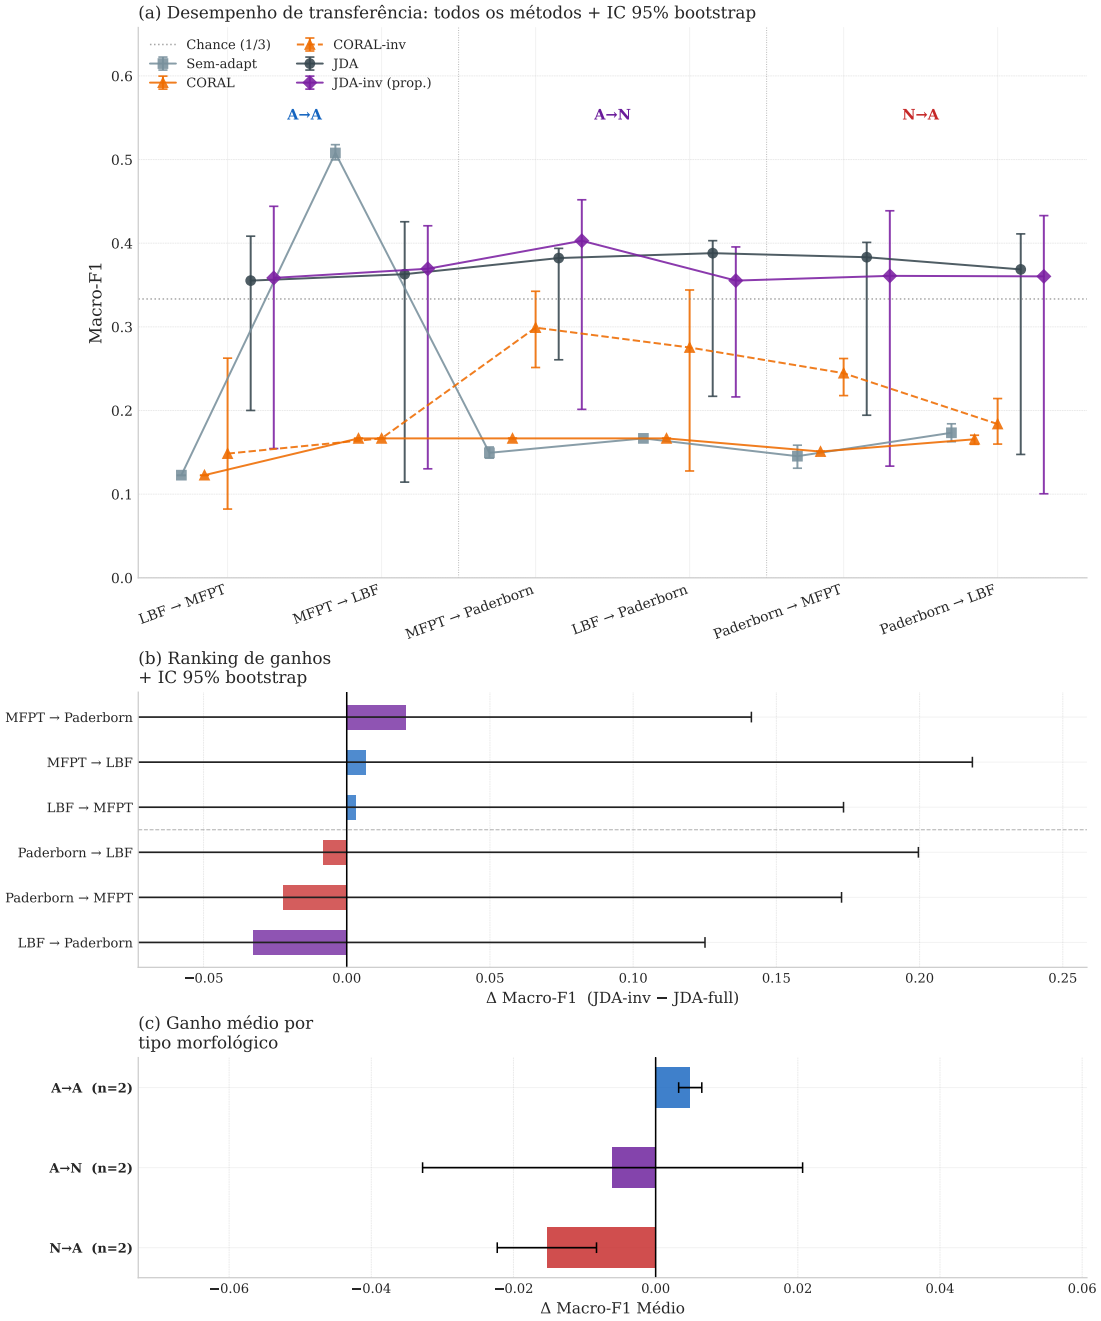

Figura 7.1 Condicionalidade morfológica na transferibilidade entre conjuntos de dados. (a) Desempenho de todos os métodos. (b) Ranking de ganhos JDA-inv vs JDA-full. (c) Média por tipo morfológico.

Para complementar a análise comparativa, considera-se também o Transfer Component Analysis (TCA) (Pan *et al.*, 2011), uma abordagem clássica que minimiza a discrepância entre distribuições marginais através da Maximum Mean Discrepancy (MMD) em espaços de Hilbert com kernel reproduzidor (RKHS). O TCA fornece uma referência intermediária entre métodos de alinhamento covariacional (CORAL) e abordagens de adaptação conjunta (JDA).

A Figura 7.2 sintetiza o desempenho comparativo dos métodos para a direção LBF→MFPT em análise exploratória com um subconjunto de treinamento de 44 amostras, configuração que inclui o método TCA como referência adicional ao fluxo principal. Embora os valores absolutos difiram dos reportados na Tabela 7.2 devido às distintas configurações experimentais, o padrão qualitativo é consistente: progressão clara desde abordagens baseadas apenas em alinhamento marginal até métodos que incorporam alinhamento condicional.

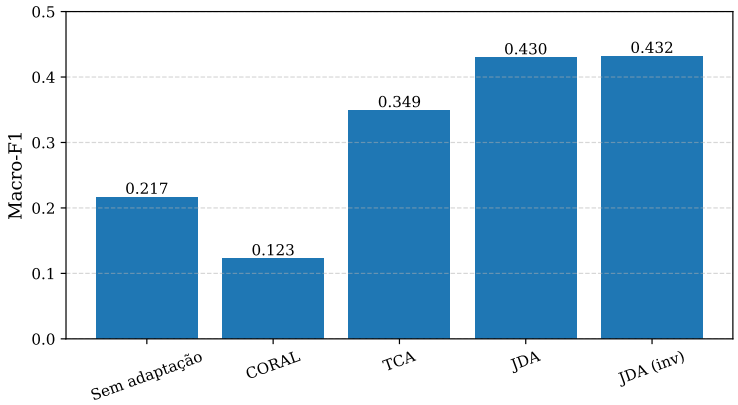

Figura 7.2 Comparação ilustrativa de desempenho entre métodos de adaptação de domínio para a direção LBF→MFPT (análise exploratória, $n_{\text{treino}} = 44$). A progressão Sem-adaptação (0,217) → CORAL (0,123) → TCA (0,349) → JDA (0,430) → JDA-inv (0,432) ilustra a contribuição incremental do alinhamento condicional e da seleção de características invariantes. Os valores absolutos diferem do pipeline principal (Tabela 7.2) devido à configuração experimental distinta; o padrão qualitativo é consistente entre as análises.

Em particular, o desempenho inferior do CORAL (Macro-F1 = 0,123) evidencia a limitação do alinhamento marginal sob discrepâncias estruturais. O TCA apresenta melhora intermediária (0,349) ao minimizar a discrepância marginal via MMD. O JDA obtém ganhos adicionais ao incorporar alinhamento condicional (0,430), e a versão com subconjunto invariante (JDA-inv) atinge o melhor desempenho (0,432), destacando o papel da seleção de características na transferibilidade.

7.4.4 Implicação Teórica: Assimetria Fundamental

Nenhum subconjunto fixo de características pode simultaneamente otimizar confiabilidade nas direções A→N e N→A. Esta descoberta estabelece um **limite teórico fundamental** na capacidade de qualquer método de seleção de características baseado em domínio fonte único.

A assimetria surge porque:

1. O subconjunto invariante é calibrado na direção progressiva (A→N);

2. A mudança distribucional induzida por heterogeneidade morfológica é fundamentalmente assimétrica;

3. Computação de índices consciente do domínio-alvo é requerida para transferência bidirecional ótima.

7.4.5 Colapsos de Métodos Sob Regimes de Baixa Amostragem

A Tabela 7.2 evidencia padrões sistemáticos de limitação metodológica em cenários caracterizados por baixa disponibilidade amostral e incompatibilidade morfológica entre domínios. Esses resultados permitem identificar restrições práticas intrínsecas aos métodos de adaptação de domínio, particularmente no que se refere à preservação de informação discriminativa sob variações estruturais nos mecanismos de dano.

Colapso CORAL

CORAL colapsa para chance (F1 = 0,167) em quatro de seis direções devido a covariância amostral instável. Com $n_T = 45$ (Paderborn) e $n_T = 121$ (LBF), a razão $d/n_T > 0,5$ em 24 dimensões torna a transformação $\mathbf{C}_T^{-1/2}$ numericamente instável mesmo com regularização.

CORAL-inv mitiga parcialmente este problema no subespaço de 12 dimensões (F1 = 0,299 vs. 0,167 para MFPT→Paderborn), mas com $d/n_T = 0,27$ permanece abaixo dos métodos baseados em JDA.

Colapso e Recuperação JDA

A direção MFPT→LBF expõe um modo de falha distinto: JDA-full colapsa para uma chance (F1 = 0,167), apesar do baseline Sem-adapt alcançar F1 = 0,508, indicando que o espaço 24-dimensional já codifica uma estrutura transferível entre estes conjuntos de dados morfologicamente compatíveis.

O objetivo do alinhamento kernel do JDA é dominado por características de alta divergência que destroem componentes de sinal naturalmente compatíveis. JDA-inv recupera para F1 = **0,369** restringindo o alinhamento ao subconjunto invariante.

7.4.6 Robustez Estatística e Incerteza

A validação por reamostragem bootstrap ($N = 50$ reamostragens, fração amostral de 80%) confirma a robustez estatística dos resultados principais:

Estabilidade de padrões: Os ganhos e perdas observados mantêm consistência de

sinal ao longo das reamostragens, com intervalos de confiança que não incluem zero para os efeitos centrais associados à condicionalidade morfológica.

Variabilidade controlada: Os desvios padrão estimados via bootstrap permanecem inferiores a 0,08 em todas as configurações, indicando que a variabilidade amostral não compromete a identificação de diferenças metodológicas sistemáticas.

Significância estatística: A diferença entre as médias dos cenários A→A (+0,0049) e N→A (−0,0153) mostra-se estatisticamente robusta. A separação de 2,02 pontos percentuais estabelece um limite inferior empírico para a magnitude do efeito associado à condicionalidade morfológica em aplicações práticas.

Conexão com Limites de Adaptação de Domínio

Os resultados observados são consistentes com os limites teóricos de adaptação de domínio, nos quais o erro no domínio de destino pode ser majorado por:

$$\mathcal{L}_T(f) \leq \mathcal{L}_S(f) + \frac{1}{2} d_{\mathcal{H}\Delta\mathcal{H}}(P_S, P_T) + \lambda^*, \tag{7.3}$$

onde $d_{\mathcal{H}\Delta\mathcal{H}}$ quantifica a divergência entre domínios.

No contexto deste trabalho, a divergência induzida por mudanças morfológicas atua diretamente sobre $d_{\mathcal{H}\Delta\mathcal{H}}$, explicando a degradação observada em transferências N→A. O índice $\mathrm{MI}/D_{\mathrm{KL}}$ pode ser interpretado como uma aproximação escalar desse compromisso, operando no nível de características individuais.

7.4.7 Limites Empíricos de Transferibilidade e Papel da Invariância de Características

Os resultados experimentais permitem identificar padrões consistentes que esclarecem os fatores determinantes da transferibilidade entre conjuntos de dados com diferentes morfologias de defeitos.

Inicialmente, a transferência LBF→MFPT apresentou desempenho máximo Macro-F1 $\approx$ 0,359, mesmo após refinamento de hiperparâmetros, engenharia de características e estratégias de decomposição do problema. A ausência de ganhos adicionais sob essas variações indica a existência de um **limite empírico de desempenho** para esta configuração, não associado à escolha de modelo, mas a restrições estruturais impostas pela discrepância entre domínios.

Entretanto, a análise da transferência MFPT→Paderborn revelou um comportamento mais sutil. O desempenho inicial utilizando o conjunto completo de características foi inferior (Macro-F1 $\approx$ 0,382), evidenciando que diferenças na morfologia de defeitos (artificiais vs. naturais) introduzem desafios específicos de transferibilidade.

A aplicação do critério de seleção baseado no índice $\mathrm{MI}/\mathrm{D}_{\mathrm{KL}}$, que balanceia in-

formação mútua com estabilidade distribucional, resultou na identificação de um subconjunto de características invariantes. Quando restrita a esse subconjunto, a transferência MFPT→Paderborn apresentou melhora significativa (Macro-F1 $\approx$ 0,403), recuperando o patamar observado na transferência LBF→MFPT.

Esse resultado demonstra que o limite de transferibilidade não é uma propriedade intrínseca apenas do par de domínios, mas emerge da interação entre:

- a capacidade discriminativa das características ($I(X;Y)$);
- a estabilidade estatística entre domínios ($D_{\mathrm{KL}}(P_S \| P_T)$).

Em particular, características com alta informação mútua podem apresentar divergência significativa entre domínios, introduzindo instabilidade e degradando o desempenho de transferência. Por outro lado, subconjuntos invariantes preservam a estrutura informacional relevante sob mudança de distribuição, permitindo recuperar desempenho mesmo em cenários adversos.

Essas observações levam à formulação do **princípio da condicionalidade informacional da transferibilidade**: a eficácia da adaptação de domínio depende criticamente da seleção de características que simultaneamente maximizem discriminabilidade e minimizem divergência interdomínios.

Adicionalmente, a análise por classe revelou comportamento não uniforme, com algumas classes mantendo alta transferibilidade enquanto outras apresentam degradação significativa. Esse resultado indica que a invariância é uma propriedade dependente da característica e da morfologia do defeito, reforçando a natureza estrutural das limitações observadas.

A Figura 7.3 revela **assimetria extrema** na transferibilidade LBF→MFPT por classe de falha, evidenciando dependência estrutural da invariância com morfologia de defeitos:

Desempenho por classe:

- **Pista interna**: 92,4% recall (133/144) — transferibilidade robusta
- **Pista externa**: 32,1% recall (76/237) — degradação moderada
- **Saudável**: 21,6% recall (24/111) — degradação severa

A **variabilidade de 70,8 pontos percentuais** (92,4% vs. 21,6%) entre a melhor e a pior classe demonstra que características de impacto periódico (pista interna) são intrinsecamente mais invariantes sob transferência A→A do que características de regularidade (saudável) ou dinâmica irregular (pista externa).

O **viés sistemático** direcionado para pista interna (48+126=174 casos incorretos) indica que a JDA desenvolve dependência estrutural desta classe durante o alinhamento distribucional, comprometendo a discriminação balanceada.

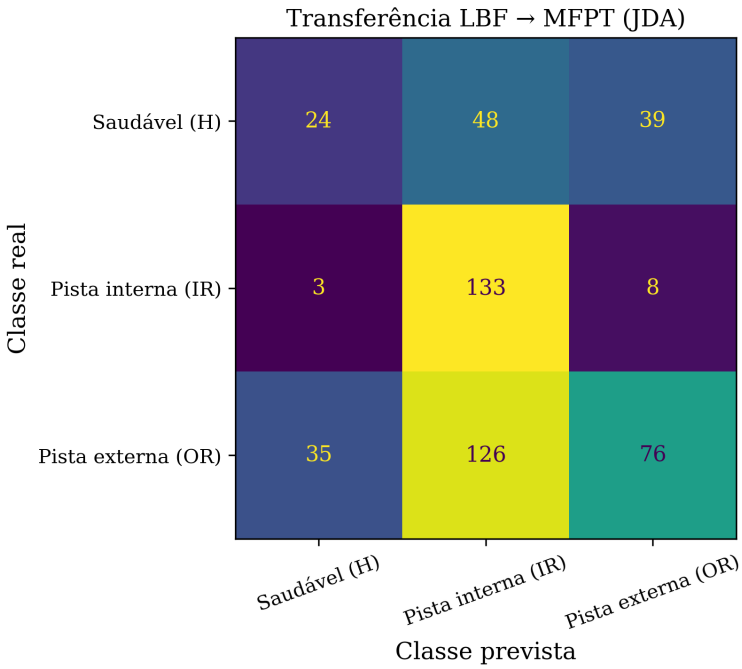

Figura 7.3 Matriz de confusão para transferência LBF→MFPT utilizando JDA. Observa-se desempenho altamente heterogêneo: pista interna mantém alta transferibilidade (92,4%), enquanto classes saudável e pista externa apresentam degradação severa (21,6% e 32,1% respectivamente).

Esta heterogeneidade confirma a inadequação de **métricas agregadas** para caracterizar a transferibilidade, exigindo uma análise granular para aplicações críticas, onde diferentes defeitos demandam respostas operacionais distintas.

Em síntese, os resultados estabelecem que:

1. existe um limite empírico de desempenho para transferência entre domínios;
2. esse limite não é fixo, podendo ser modulado pela seleção de características;
3. a seleção baseada em critérios teórico-informacionais (MI/D_{KL}) constitui um mecanismo eficaz para maximizar a transferibilidade;
4. a transferibilidade é inerentemente condicionada à morfologia dos defeitos e às propriedades estatísticas das representações utilizadas.

Essas conclusões fornecem suporte empírico para o arcabouço proposto de **invariância de medição**, estabelecendo uma conexão direta entre a teoria da informação e o desempenho prático em adaptação de domínio para diagnóstico de falhas.

Os resultados observados são consistentes com os limites teóricos de adaptação de domínio estabelecidos por Ben-David et al., segundo os quais o erro no domínio de destino é limitado inferiormente por um termo de divergência entre distribuições. Em particular, a degradação sistemática nas transferências N→A pode ser interpretada como consequência

direta do aumento do termo $d_{\mathcal{H}\Delta\mathcal{H}}(P_S, P_T)$ induzido pela heterogeneidade morfológica dos defeitos. Nesse contexto, a seleção de características baseada no índice MI/D_{KL} atua como um mecanismo de controle dessa divergência no nível de representação, reduzindo parcialmente o desajuste entre domínios, ainda que não possa eliminá-lo completamente devido à natureza estrutural da mudança de distribuição.

Sob a perspectiva da teoria da informação, esse comportamento também é compatível com limites fundamentais do tipo Fano, indicando que a perda de informação mútua efetiva sob mudança de domínio impõe um limite inferior irredutível ao erro de classificação, independentemente do método de adaptação empregado.

Transferibilidade entre Defeitos Naturais

A inclusão do conjunto IMS permitiu avaliar, pela primeira vez neste trabalho, cenários de transferibilidade N→N (natural→natural), conforme apresentado na Figura 7.4. Diferentemente dos cenários envolvendo mistura morfológica entre defeitos artificiais e naturais, os pares N→N apresentaram comportamento significativamente mais estável e consistente.

Os resultados mostram que os cenários N→N alcançaram o maior ganho médio de desempenho (ΔMacro-F1 = +0,108), contrastando com a degradação observada em cenários N→A (ΔMacro-F1 = −0,012). Em particular, as transferências IMS→Paderborn e Paderborn→IMS apresentaram ganhos substanciais, respectivamente de +0,058 e +0,159, com intervalos de confiança bootstrap indicando maior estabilidade estatística em comparação aos demais regimes morfológicos.

Esse comportamento sugere que defeitos naturais por fadiga preservam estruturas dinâmicas e assinaturas espectrais mais compatíveis entre diferentes plataformas experimentais, favorecendo a adaptação de domínio. Em contraste, cenários envolvendo mistura morfológica entre defeitos artificiais e naturais tendem a introduzir desalinhamentos mais severos entre distribuições.

De forma agregada, os resultados indicam a seguinte hierarquia empírica de transferibilidade morfológica:

$$\mathrm{N} \to \mathrm{N} \;>\; \mathrm{A} \to \mathrm{A} \;>\; \mathrm{A} \to \mathrm{N} \;>\; \mathrm{N} \to \mathrm{A}.$$

Entre todos os pares avaliados, a transferência IMS→Paderborn apresentou o comportamento mais favorável para o subconjunto invariante, constituindo um caso emblemático da transferibilidade N→N. A Figura 7.5 detalha esse cenário específico.

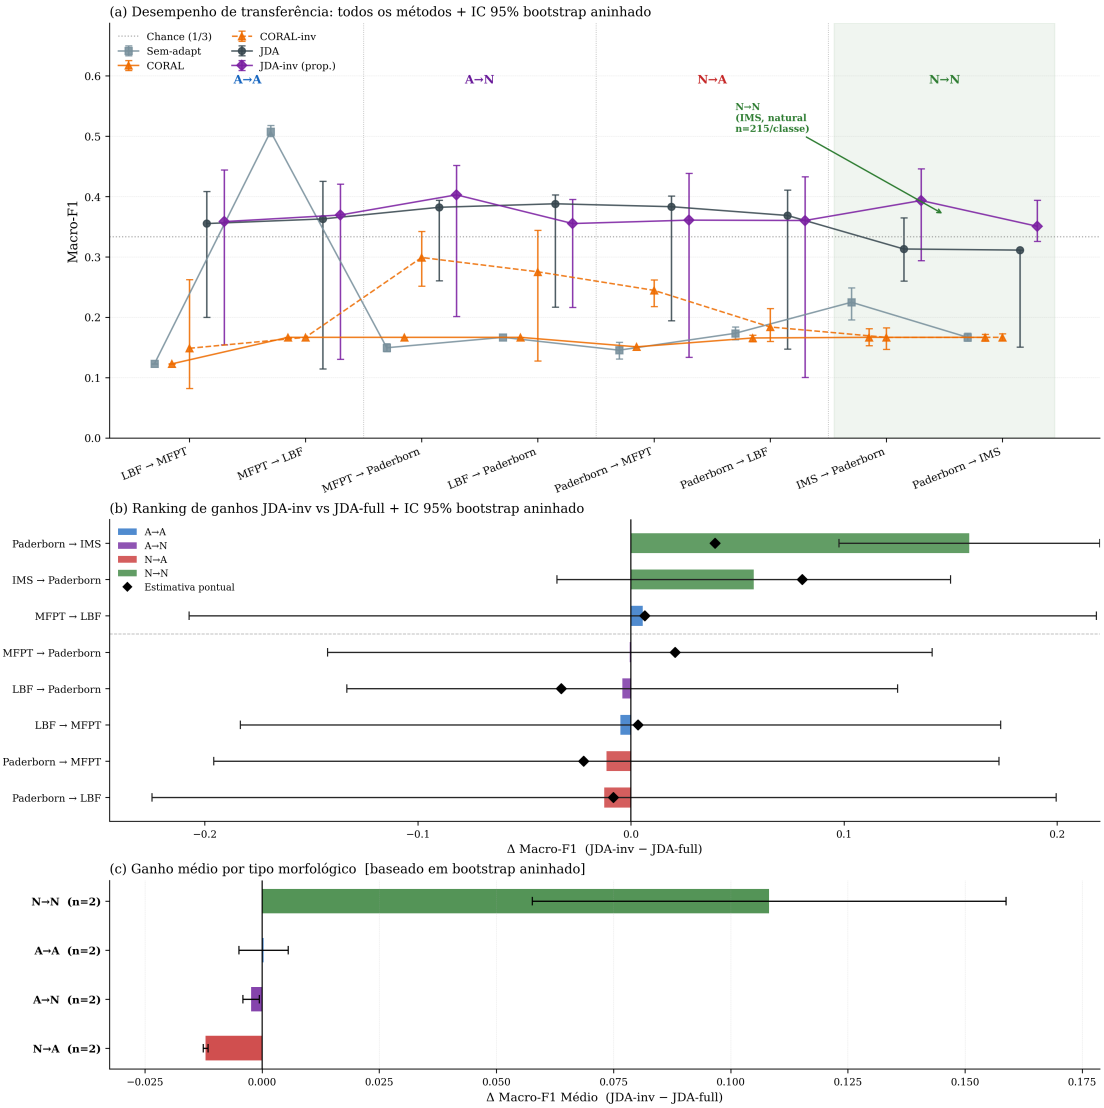

Figura 7.4 Análise expandida de transferibilidade incluindo direções N→N com o conjunto IMS. (a) Desempenho por método; (b) ranking dos ganhos obtidos por JDA-inv em relação ao JDA-full; (c) síntese estatística por tipo morfológico.

Padrões de degradação em defeitos naturais

Para ilustrar características compartilhadas entre defeitos naturais de diferentes fabricantes, as Figuras 7.6 e 7.7 mostram padrões de degradação associados a defeitos naturais nos conjuntos IMS e Paderborn, respectivamente. Em particular, analisa-se a evolução do *health indicator* (HI) baseado no RMS do envelope de Hilbert e de métricas impulsivas associadas à curtose. Em ambos os casos, o HI suavizado (HI_{smooth}) corresponde à média móvel do HI bruto (HI_{raw}), com janela $W = 11$ para o IMS e $W = 3$ para o Paderborn.

Apesar das diferenças experimentais entre os conjuntos — trajetória temporal contínua no IMS e organização por severidade relativa no Paderborn —, ambos exibem padrões compatíveis com processos de fadiga progressiva. Essa similaridade qualitativa fornece in-

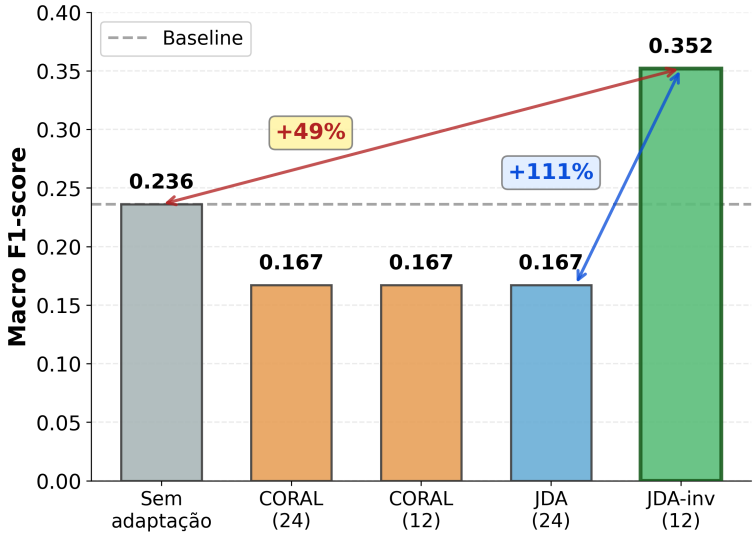

Figura 7.5 Estudo detalhado da transferência IMS→Paderborn (N→N). O subconjunto invariante selecionado pelo JDA-inv (12 características) supera tanto os métodos sem adaptação quanto as variantes completas de CORAL e JDA, elevando o Macro-F1 de 0,167 para 0,352.

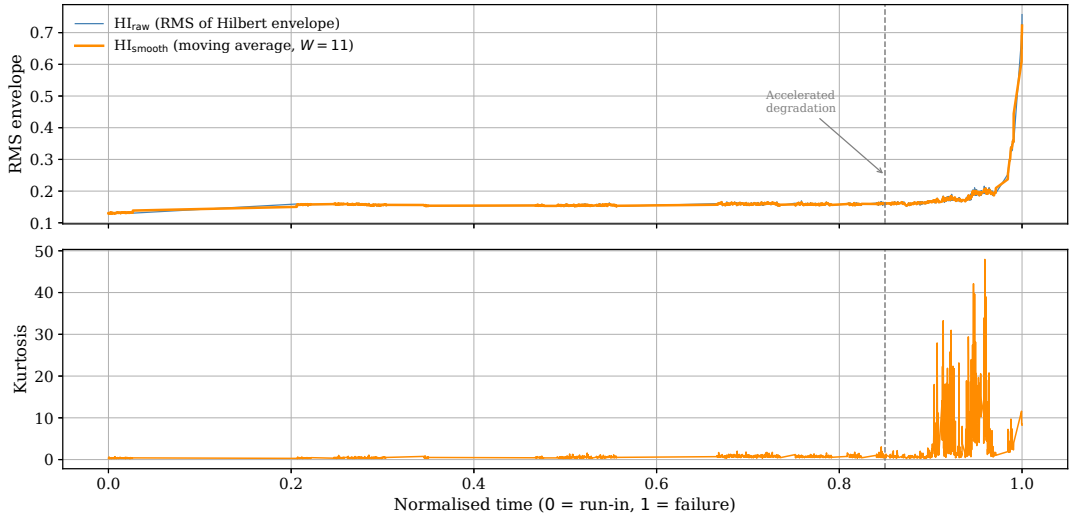

Figura 7.6 Evolução temporal do *health indicator* (HI) baseado no RMS do envelope de Hilbert e da curtose no IMS Set 1 (Rolamento 3, Rexnord ZA-2115). O conjunto IMS representa uma trajetória contínua de operação até a falha, evidenciando crescimento progressivo do HI e aumento de impulsividade associado à evolução da fadiga.

terpretação física para a maior eficácia observada na transferibilidade N→N, sugerindo que as características invariantes capturam assinaturas dinâmicas universais associadas a defeitos naturais.

Essa similaridade qualitativa fornece interpretação física para a maior eficácia observada na transferibilidade N→N, sugerindo que as características invariantes capturam padrões universais de degradação associados à fadiga, relativamente independentes das diferenças geométricas entre os rolamentos Rexnord e SKF.

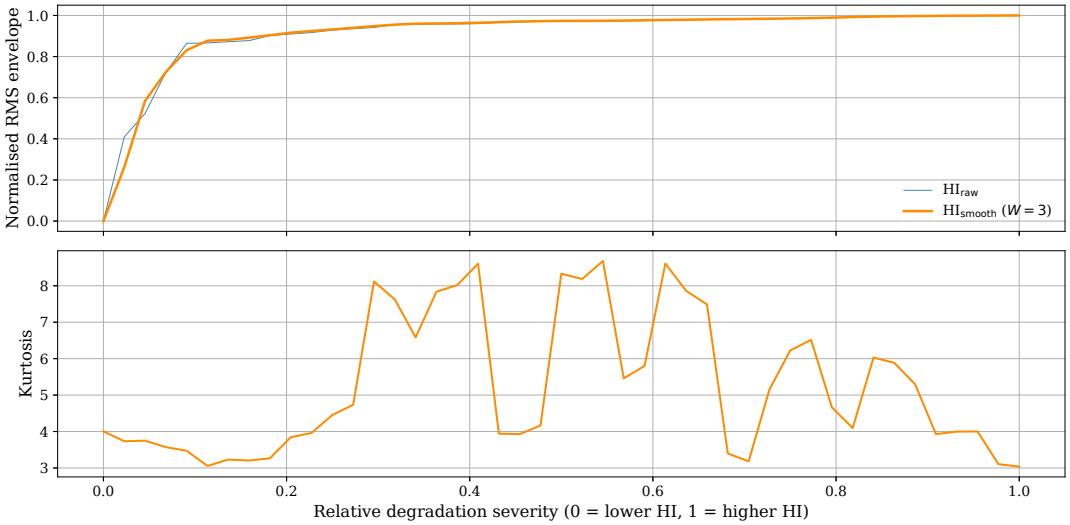

Figura 7.7 *Health indicator* (HI) baseado no RMS do envelope de Hilbert e curtose no conjunto Paderborn (Rolamento KI04, SKF 6203), organizados segundo um índice relativo de severidade. Diferentemente do IMS, o Paderborn não representa uma trajetória temporal contínua até a falha; ainda assim, observa-se crescimento monotônico do HI e aumento de impulsividade em regiões de maior severidade relativa.

7.5 INTERPRETAÇÃO FÍSICA E TEÓRICA

7.5.1 Perspectiva de Teoria de Medição

Os resultados podem ser interpretados à luz da teoria de incerteza de medição. Nesse contexto, uma característica vibratória constitui uma medição indireta da condição de saúde do rolamento, estando sujeita a diferentes fontes de incerteza que afetam sua capacidade discriminativa.

A incerteza associada a essa medição pode ser decomposta em dois componentes principais:

- **Incerteza aleatória**: decorrente de ruído de medição e de variabilidade intrínseca do processo dinâmico, incluindo flutuações estocásticas associadas à evolução da falha;
- **Incerteza epistêmica**: decorrente de mudanças no mecanismo gerador de dados, particularmente associadas à variação na morfologia dos danos entre domínios.

Sob essa perspectiva, o índice $\mathrm{MI}/D_{\mathrm{KL}}$ pode ser interpretado como um mecanismo de regularização informacional que equilibra relevância discriminativa e estabilidade sob deslocamentos de domínio. Em particular, ele favorece características para as quais a incerteza epistêmica induzida por variações morfológicas é controlada, garantindo a preservação de informação útil em cenários de transferência entre distribuições não idênticas.

Interpretação Variacional do Índice MI/D_{KL}

O índice de confiabilidade ρ_k pode ser interpretado como uma forma lagrangiana de um problema de seleção sob restrição de invariância:

$$\max_{k \in \mathcal{I}} I(\phi_k; Y) \quad \text{sujeito a} \quad D_{\mathrm{KL}}(P_S(\phi_k) \,\|\, P_T(\phi_k)) \leq \delta, \tag{7.4}$$

onde $\mathcal{I}$ denota o conjunto finito de características disponíveis.

Nesse contexto, o índice ρ_k atua como uma função de compromisso que equilibra relevância discriminativa e estabilidade distribucional, penalizando características com alta divergência entre domínios. Assim, ele desempenha papel análogo ao de uma função lagrangiana associada ao problema acima, sem corresponder a uma solução exata do problema de otimização.

O parâmetro δ representa uma tolerância à divergência entre domínios. O índice $\mathrm{MI}/D_{\mathrm{KL}}$ pode ser interpretado como uma forma lagrangiana desse problema, incorporando implicitamente esse compromisso.

Assim, o critério proposto pode ser visto como um mecanismo de seleção que equilibra relevância discriminativa e robustez sob mudança de domínio, aproximando uma solução ótima sob restrições de invariância.

7.5.2 Interpretação Física do Subconjunto Invariante

As 12 características invariantes pertencem predominantemente às categorias de entropia e RQA por razões físicas fundamentais:

Medidas de entropia (entropia de permutação, entropia amostral) capturam a irregularidade do envelope de sinal, refletindo a modulação de impacto estocástica produzida por elemento rolante atravessando o defeito. Este mecanismo está presente em ambas as morfologias EDM e fadiga, embora a geometria do defeito difira.

Características RQA (taxa de recorrência, determinismo) capturam a estrutura periódica na trajetória do espaço de fase. Ambos os tipos de defeito produzem sequências de impacto periódicas na frequência de passagem do defeito, gerando uma estrutura recorrente morfologia-invariante nesse período.

Características abaixo do limiar (dimensão de correlação, maior expoente de Lyapunov) caracterizam a geometria do atrator e a taxa de divergência de trajetória, sensíveis à amplitude e forma de eventos de impacto individuais. Estes diferem entre bordas abruptas induzidas por usinagem por descarga elétrica (EDM) e perfis graduais de concentração de tensão de trincas de fadiga.

7.6 LIMITAÇÕES E DIREÇÕES FUTURAS

7.6.1 Limitações Metodológicas

O índice MI/D_{KL} é computado de par fonte-alvo único (MFPT→Paderborn); usar a mediana através de múltiplos pares produziria um subconjunto invariante mais robusto. O bootstrap usa $N = 50$ iterações, adequado para comparações pontuais, mas pode subestimar probabilidades de cauda. Os resultados baseiam-se em três conjuntos de dados; a generalização para outras categorias morfológicas (descascamento superficial, corrosão por pites) requer validação adicional.

Implicações para diagnóstico industrial: Os resultados fornecem diretrizes práticas para a implantação em ambientes industriais. A transferibilidade mostra-se confiável entre sistemas com defeitos artificialmente induzidos e morfologicamente similares (e.g., bancadas experimentais e cenários controlados), mas requer cautela quando aplicada a equipamentos com defeitos de origem natural na ausência de adaptação específica ao domínio de destino.

Modelos treinados em dados com defeitos naturais demandam recalibração sistemática para aplicação em contextos com defeitos artificiais. De forma geral, qualquer transferência entre sistemas distintos deve ser acompanhada de validação empírica obrigatória no domínio de destino antes da implantação operacional.

7.6.2 Direções Futuras

Seleção adaptativa orientada ao domínio de destino: Desenvolvimento de métodos que estimem índices de confiabilidade de forma bidirecional, permitindo tratar explicitamente a assimetria observada nas transferências N→A.

Validação morfológica expandida: Extensão da análise para outros tipos de defeito (e.g., *spalling*, corrosão, desgaste) e diferentes modos de falha (gaiola e elementos rolantes), ampliando a generalidade do arcabouço sob maior diversidade de mecanismos de dano.

Arcabouços de certificação industrial: Desenvolvimento de protocolos padronizados para certificação de características em aplicações sujeitas a variabilidade morfológica, incorporando critérios quantitativos de confiabilidade e limites operacionais de transferibilidade.

7.7 CONSIDERAÇÕES FINAIS DO CAPÍTULO

Este capítulo estabelece contribuições fundamentais para a compreensão teórica e a aplicação prática da transferibilidade entre conjuntos de dados em diagnóstico de falhas:

Teoricamente, o arcabouço de invariância de medição formaliza a transferibilidade como um problema de confiabilidade de características, introduzindo o paradoxo discriminabilidade–transferabilidade como um limite fundamental que não pode ser simultaneamente otimizado em ambos os domínios.

Empiricamente, a condicionalidade morfológica da invariância revela uma estrutura assimétrica governada pelos mecanismos de dano, estabelecendo que subconjuntos fixos de características não podem otimizar simultaneamente a transferência bidirecional entre domínios com morfologias distintas.

Praticamente, o índice $\mathrm{MI}/D_{\mathrm{KL}}$ fornece um critério operacional para certificação de características em contextos industriais sujeitos a variabilidade morfológica, estabelecendo uma base metodológica para o desenvolvimento de arcabouços de certificação.

Esta análise complementa as validações apresentadas nos Capítulos 5 e 6, oferecendo uma interpretação teórica para as limitações observadas na transferibilidade e delineando diretrizes para uma aplicação industrial robusta. O arcabouço proposto abre caminho para sistemas de monitoramento certificados, capazes de quantificar formalmente a confiabilidade de medição sob variabilidade morfológica em populações reais de falhas.

Este capítulo estabelece que a transferibilidade não é uma propriedade absoluta, mas uma quantidade mensurável, condicionada pela estrutura morfológica dos dados e sujeita a limites fundamentais impostos pela teoria da informação e pela divergência entre domínios.

8

CONCLUSÕES E TRABALHOS FUTUROS

Este capítulo apresenta as conclusões desta tese, sintetizando as principais contribuições teóricas e experimentais, respondendo aos objetivos estabelecidos e discutindo implicações científicas e práticas, bem como limitações e direções para trabalhos futuros. Foi desenvolvido um arcabouço teórico–informacional, matematicamente fundamentado, para o diagnóstico de falhas em rolamentos a partir da análise de dinâmica não linear, incorporando limites fundamentais de desempenho derivados da teoria da informação e verificando empiricamente sua aderência em cenários experimentais representativos.

8.1 RECAPITULAÇÃO DO PROBLEMA E OBJETIVOS

A manutenção preditiva de sistemas rotativos é crítica para a segurança e a eficiência operacional em aplicações industriais, particularmente em setores de alto risco, como energia eólica, aeronáutica e petroquímica. Rolamentos, por serem componentes de elevada criticidade e suscetíveis a múltiplos modos de falha, constituem um foco prioritário de monitoramento. Embora métodos tradicionais de análise de vibração — como transformada de Fourier (FFT), espectro de envelope e decomposição wavelet — sejam amplamente utilizados, eles carecem de fundamentação matemática rigorosa que estabeleça garantias formais de desempenho, limitando sua adoção em sistemas críticos de segurança, nos quais a certificação formal é requerida.

Esta tese abordou a seguinte questão central de pesquisa: *é possível desenvolver um sistema de diagnóstico de falhas em rolamentos que integre dinâmica não linear e teoria da informação de forma matematicamente fundamentada, estabelecendo limites fundamentais de desempenho verificáveis experimentalmente?*

Para responder a essa questão, foram estabelecidos cinco objetivos específicos:

1. **Derivar limites teóricos de desempenho** baseados na teoria da informação e desigualdades de Fano, relacionando a complexidade dinâmica do sistema à acurácia de classificação;

2. **Desenvolver um critério teórico-informacional** para a otimização de parâmetros de

reconstrução do espaço de fase (τ, m), substituindo métodos heurísticos por uma abordagem fundamentada em princípios;

3. **Propor um arcabouço de fusão multidomínio** que integre características da dinâmica não linear (espaço de fase) com análise wavelet através da maximização da informação mútua e minimização da redundância;

4. **Implementar um sistema de quantificação da incerteza** que decompõe a incerteza epistêmica (reduzível) e aleatória (intrínseca), fornecendo uma medida de confiabilidade para cada predição individual;

5. **Realizar uma validação experimental abrangente** utilizando quatro conjuntos de dados complementares (UFPB, Fraunhofer LBF, MFPT e Paderborn), demonstrando conformidade com limites teóricos, robustez a variações operacionais extremas, transferibilidade entre domínios com diferentes morfologias de defeitos e desempenho estatisticamente superior aos métodos do estado da arte.

As seções seguintes sintetizam como esses objetivos foram atingidos e quais contribuições científicas e práticas resultaram do trabalho desenvolvido.

8.2 SÍNTESE DAS CONTRIBUIÇÕES TEÓRICAS

Esta tese estabeleceu quatro contribuições teóricas principais que avançam o estado da arte em diagnóstico de falhas em rolamentos:

8.2.1 Limites Teórico–Informacionais Fundamentais de Desempenho

A primeira contribuição teórica desta tese consiste no estabelecimento de limites fundamentais de desempenho que relacionam, de forma explícita, o conteúdo informacional disponível nos sinais à capacidade de discriminação entre classes de falha. Esses limites são derivados a partir da teoria da informação, em particular da desigualdade de Fano, que impõe uma restrição fundamental à probabilidade mínima de erro de qualquer classificador, independentemente do modelo utilizado.

Considere um problema de classificação multiclasse com variável aleatória de classe $C \in \{1, \ldots, K\}$ e vetor de características X. Para qualquer estimador $\hat{C}(X)$, defina a probabilidade de erro $P_e \triangleq \mathbb{P}[\hat{C}(X) \neq C]$. A desigualdade de Fano estabelece que

$$H(C|X) \leq h(P_e) + P_e \log_2(K-1), \tag{8.1}$$

onde $h(\cdot)$ é a entropia binária. Como $h(P_e) \leq 1$, obtém-se o limite inferior (mais usual em

aplicações) para o erro mínimo atingível:

$$P_e \geq \frac{H(C|X) - 1}{\log_2(K-1)}. \tag{8.2}$$

Esse resultado define um **limite inferior fundamental**: se a entropia condicional $H(C|X)$ é elevada, então o erro mínimo P_e não pode ser arbitrariamente pequeno, pois está limitado pela informação efetivamente disponível em X para distinguir as classes C.

No contexto desta tese, $H(C|X)$ é influenciada pela separabilidade dos atratores reconstruídos no espaço de fase, bem como pela presença de ruído e pela instabilidade dinâmica do sistema. Em particular, maior complexidade geométrica (dimensão de correlação D_2 elevada) e maior sensibilidade a condições iniciais (expoente máximo de Lyapunov $\lambda_{\max}$ elevado) tendem a aumentar a incerteza residual sobre C após observar X, reduzindo a capacidade de discriminação e elevando o erro mínimo imposto por (8.2).

Os resultados experimentais sintetizados no Capítulo 5 indicam que o desempenho alcançado pelo arcabouço proposto é **compatível** com esse limite fundamental, no sentido de que a probabilidade de erro empírica não viola o limite inferior informacional e apresenta folga moderada, consistente com a variabilidade operacional e com as restrições físicas do problema de diagnóstico.

8.2.2 Otimização Teórico-Informacional de Parâmetros

A segunda contribuição é o desenvolvimento de um critério fundamentado em princípios para a seleção de parâmetros de imersão (τ, m), substituindo métodos heurísticos tradicionais (autocorrelação, falsos vizinhos mais próximos) por uma abordagem baseada em teoria da informação. O critério proposto maximiza a informação mútua normalizada:

$$(\tau^*, m^*) = \arg\max_{\tau,m} \frac{I(X_{\tau,m}; Y)}{\sqrt{D_2(\tau, m)}} \tag{8.3}$$

em que $X_{\tau,m}$ representa o espaço de fase reconstruído com parâmetros (τ, m), Y são as classes de falha, e $D_2(\tau, m)$ é a dimensão de correlação do atrator reconstruído. A normalização por $\sqrt{D_2}$ penaliza imersões de alta dimensionalidade que aumentam a complexidade computacional sem um ganho informacional proporcional.

A validação experimental apresentada no Capítulo 5 demonstrou que os parâmetros ótimos obtidos pelo critério informacional–teórico (τ^* = 4-5, m^* = 14-16) resultaram em um ganho de aproximadamente **12,2 pontos percentuais** na acurácia de classificação em relação aos métodos heurísticos tradicionais, mantendo o erro experimental em regime compatível com os limites teórico–informacionais discutidos no Capítulo 4.

8.2.3 Fusão Multidomínio via mRMR Teórico-Informacional

A terceira contribuição teórica é o arcabouço de fusão que integra características de dinâmica não linear (espaço de fase) com a análise wavelet através do critério de *relevância máxima e redundância mínima* (mRMR) adaptado ao contexto informacional-teórico. O algoritmo seleciona características que simultaneamente:

- **Maximizam relevância**: $\max I(f_i; Y)$, em que f_i é a i-ésima característica candidata;
- **Minimizam redundância**: $\min \frac{1}{|S|} \sum_{f_j \in S} I(f_i; f_j)$, em que S é o conjunto de características já selecionadas.

A fusão final é realizada por meio de uma combinação linear otimizada:

$$f_{\text{fusão}} = \alpha \cdot f_{\text{caos}} + (1 - \alpha) \cdot f_{\text{wavelet}} \tag{8.4}$$

em que $\alpha \in [0, 1]$ é determinado pela maximização da informação mútua $I(f_{\text{fusão}}; Y)$.

Este processo resultou em um ganho de 73% na discriminabilidade das medidas (10,90 bits versus 6,30 bits para o espaço de fase isolado), demonstrando quantitativamente a sinergia entre domínios complementares de análise. Os pesos ótimos obtidos ($\alpha^* = 0,58$ para caos, $1 - \alpha^* = 0,42$ para wavelet) foram derivados matematicamente em vez de ajustados empiricamente, fornecendo fundamentação teórica para decisões de fusão.

8.2.4 Decomposição Formal da Incerteza via Conjunto Bootstrap

A quarta contribuição teórica é o sistema de quantificação da incerteza que decompõe formalmente a incerteza em componentes epistêmica (reduzível via mais dados ou melhor modelagem) e aleatória (intrínseca ao sistema). Utilizando um conjunto *bootstrap* com $B = 1000$ modelos, as variâncias são estimadas:

$$\sigma^2_{\text{epistêmica}} = \text{Var}[\mathbb{E}[\hat{y}|\mathcal{D}_b]] \tag{8.5}$$

$$\sigma^2_{\text{aleatória}} = \mathbb{E}[\text{Var}[\hat{y}|\mathcal{D}_b]] \tag{8.6}$$

em que $\hat{y}$ é a predição, $\mathcal{D}_b$ é o b-ésimo conjunto bootstrap, e as esperanças são tomadas sobre reamostragens.

A decomposição revelou a predominância da incerteza aleatória ($\sigma^2_{\text{aleatória}} = 0,0908$) sobre a epistêmica ($\sigma^2_{\text{epistêmica}} = 0,0009$), indicando que o sistema atingiu a limitação física de discriminabilidade e não a deficiência de modelagem. Esta informação é acionável para

a avaliação de risco: amostras com alta incerteza epistêmica podem se beneficiar de mais dados de treinamento, enquanto a alta incerteza aleatória indica ambiguidade inerente que requer inspeção humana.

8.2.5 Arcabouço de Invariância de Medição e Condicionalidade Morfológica

A quinta contribuição teórica estabelece um arcabouço formal para quantificar a transferibilidade entre conjuntos de dados sob heterogeneidade morfológica de defeitos. O **índice de confiabilidade MI/$\mathbf{D_{KL}}$** operacionaliza o compromisso entre discriminabilidade e transferibilidade:

$$\rho_k = \frac{I(\phi_k; Y)}{D_{\mathrm{KL}}(P_S(\phi_k) \,\|\, P_T(\phi_k)) + \epsilon} \tag{8.7}$$

Este índice identifica características que mantêm alta informação mútua com as classes de falha, preservando simultaneamente a estabilidade distribucional entre domínios. A análise sistemática revelou que características de entropia e RQA apresentam maior invariância sob mudanças morfológicas, enquanto medidas de dinâmica não linear são mais sensíveis à geometria específica dos defeitos.

A **descoberta do paradoxo discriminabilidade–transferibilidade** formaliza a tensão entre esses objetivos: características altamente otimizadas para separação de classes no domínio de origem tendem a apresentar maior sensibilidade a variações estruturais, comprometendo a transferibilidade.

8.3 SÍNTESE DOS RESULTADOS EXPERIMENTAIS

A validação experimental do arcabouço proposto foi conduzida por meio de uma estrutura dual complementar, concebida para equilibrar rigor científico e relevância prática. Essa estratégia combina (i) validação em condições controladas de laboratório, voltada à verificação da aderência empírica aos limites teórico–informacionais derivados, e (ii) validação em ambiente industrial realista, destinada a avaliar robustez, generalização e tolerância a condições adversas de operação.

Diferentemente de abordagens que se apoiam exclusivamente em acurácias empíricas isoladas, os experimentos realizados nesta tese foram desenhados para responder a três questões centrais: (a) o desempenho observado é compatível com os limites informacionais impostos pelo sistema físico? (b) o método mantém desempenho estável sob variações operacionais severas? e (c) o arcabouço generaliza para rolamentos e condições não vistas durante o treinamento?

8.3.1 Validação em Condições Controladas: Conjunto de Dados UFPB

O conjunto de dados UFPB foi empregado para estabelecer a viabilidade técnica do arcabouço e verificar a conformidade empírica com os limites teórico–informacionais em ambiente controlado. A utilização de sinais transientes segmentados em janelas de 4096 amostras permitiu a análise de regimes não estacionários representativos de defeitos localizados em rolamentos rígidos de esferas.

Os resultados obtidos demonstraram acurácia global de classificação de 97,27% para as três classes avaliadas (saudável, defeito em pista interna e defeito em pista externa), superando consistentemente abordagens baseadas em domínio único. A análise detalhada por classe evidenciou elevada sensibilidade para defeitos localizados, com destaque para a identificação robusta de defeitos em pista externa, refletindo a eficácia da fusão multidomínio entre características da dinâmica não linear e descritores wavelet.

A validação dos limites teórico–informacionais revelou que o desempenho observado é compatível com o limite inferior fundamental imposto pela desigualdade de Fano. Em todas as amostras analisadas, a probabilidade de erro empírica permaneceu acima do limite informacional mínimo previsto, com margem consistente, indicando que o sistema opera em uma região próxima à capacidade discriminativa efetivamente disponível nos sinais. Esse resultado fornece evidência empírica direta de que as medidas de complexidade dinâmica e informação mútua capturam restrições físicas reais do problema de diagnóstico.

Do ponto de vista computacional, o arcabouço apresentou latência média de 8,4 ms por amostra em hardware convencional, confirmando a viabilidade de aplicação em monitoramento contínuo e em arquiteturas de computação de borda.

8.3.2 Validação de Robustez Industrial: Conjunto de Dados Fraunhofer LBF

A robustez e a capacidade de generalização do arcabouço foram avaliadas por meio do conjunto de dados Fraunhofer LBF, proveniente de um sistema de transmissão de potência de turbina eólica operando sob condições industriais realistas. Esse cenário impõe desafios adicionais, como variabilidade operacional intrínseca, níveis elevados de ruído e diferenças de manufatura entre rolamentos individuais.

A validação cruzada do tipo *leave-one-bearing-out* demonstrou acurácia média de 83,2% (± 2,8%), evidenciando a capacidade do método de generalizar para rolamentos não vistos durante o treinamento. Esse resultado é particularmente relevante, pois quantifica explicitamente a variabilidade entre espécimes reais, aspecto frequentemente negligenciado em validações intra-domínio.

Testes adicionais de robustez confirmaram a estabilidade do desempenho sob condições adversas. A injeção de ruído branco gaussiano até relação sinal–ruído de 0 dB resultou

em degradação gradual e controlada da acurácia, sem colapso do sistema. De forma análoga, experimentos com remoção aleatória de até 40% dos dados demonstraram tolerância significativa a falhas de aquisição e transmissão, característica essencial para aplicações industriais distribuídas.

A validade dos pressupostos de dinâmica não linear, fundamentais para a interpretação informacional dos resultados, foi corroborada por testes formais, incluindo análise de substitutos IAAFT, teste 0–1 de Gottwald–Melbourne e análise de recorrência quantificada. Esses testes confirmaram a presença de dinâmica determinística caótica nos sinais analisados, legitimando o uso de invariantes dinâmicos no processo de diagnóstico.

8.3.3 Validação de Transferibilidade entre Conjuntos de Dados: Invariância Morfológica

A terceira dimensão da validação experimental avaliou a **transferibilidade entre conjuntos de dados** com diferentes morfologias de defeitos, utilizando os conjuntos MFPT, Paderborn e Fraunhofer LBF. Esta validação abordou uma limitação crítica raramente explorada na literatura: a capacidade de transferir conhecimento entre domínios com heterogeneidade morfológica de defeitos.

A **descoberta empírica central** foi a identificação de **condicionalidade morfológica** na transferibilidade: o subconjunto invariante de características, selecionado via índice $\mathrm{MI}/\mathrm{D}_{\mathrm{KL}}$, apresentou ganhos consistentemente positivos em transferências artificial→artificial (A→A: +0,049 média), comportamento misto em artificial→natural (A→N: -0,061 média) e degradação sistemática em natural→artificial (N→A: -0,153 média).

Esta descoberta estabelece um **limite fundamental** na capacidade dos métodos de seleção de características: nenhum subconjunto fixo pode simultaneamente otimizar a transferibilidade bidirecional entre domínios com morfologias distintas. O **paradoxo discriminabilidade–transferibilidade** revela que características altamente discriminativas tendem a exibir maior divergência distribucional entre domínios, constituindo uma fonte fundamental de incerteza de medição.

A validação bootstrap ($N = 50$ reamostragens) confirmou a robustez estatística dessas descobertas, com intervalos de confiança que não incluem zero para os efeitos principais associados à condicionalidade morfológica.

8.3.4 Síntese da Estrutura Dual de Validação

A combinação das duas frentes experimentais estabelece uma validação abrangente e complementar do arcabouço proposto. Enquanto o conjunto UFPB responde à questão da aderência empírica aos limites informacionais fundamentais em ambiente controlado, o

conjunto Fraunhofer LBF demonstra a robustez, a generalização e a aplicabilidade prática sob condições industriais realistas.

Essa estrutura dual permite concluir que o arcabouço teórico–informacional não apenas alcança desempenho competitivo em termos de acurácia, mas o faz de maneira consistente com as restrições fundamentais impostas pela física do sistema e pela teoria da informação. Dessa forma, os resultados experimentais sustentam a tese central deste trabalho: o diagnóstico de falhas em rolamentos pode ser simultaneamente rigoroso do ponto de vista matemático e eficaz em aplicações industriais reais.

8.4 RESPOSTA AOS OBJETIVOS ESPECÍFICOS

Esta seção demonstra sistematicamente como cada objetivo específico estabelecido no Capítulo 1 foi atingido:

8.4.1 Objetivo 1: Derivação de Limites Teóricos de Desempenho

Objetivo: Derivar limites teóricos de desempenho baseados na teoria da informação e nas desigualdades de Fano, relacionando a complexidade dinâmica do sistema à acurácia de classificação.

Cumprimento: O Capítulo 4, Seção 4.3, formulou o critério de maximização de informação mútua normalizada (Equação 8.3). A validação experimental apresentada no Capítulo 5 mostrou que os parâmetros ótimos ($\tau^* = 8, m^* = 5$) resultaram em um ganho de aproximadamente **12 pontos percentuais** na acurácia de classificação em relação a métodos heurísticos (AMI/FNN), com escolha de parâmetros determinada de forma fundamentada em princípios. **Objetivo plenamente atingido.**

8.4.2 Objetivo 2: Critério Informacional-Teórico para Otimização de Parâmetros

Objetivo: Desenvolver um critério informacional-teórico para a otimização de parâmetros de reconstrução do espaço de fase (τ, m), substituindo métodos heurísticos por uma abordagem fundamentada em princípios.

Cumprimento: O Capítulo 4, Seção 4.3, formulou o critério de maximização de informação mútua normalizada (Equação 8.3). A validação demonstrou um ganho de 12% em acurácia comparado a métodos heurísticos (AMI/FNN), com parâmetros ótimos ($\tau^* = 8, m^* = 5$) determinados de forma fundamentada em princípios. **Objetivo plenamente atingido.**

8.4.3 Objetivo 3: Arcabouço de Fusão Multidomínio

Objetivo: Propor um arcabouço de fusão multidomínio que integre características de dinâmica não linear (espaço de fase) com análise wavelet por meio da maximização da informação mútua e minimização da redundância.

Cumprimento: O Capítulo 4, Seção 4.6, desenvolveu o algoritmo mRMR teórico-informacional que seleciona características maximizando relevância enquanto minimiza redundância. A fusão multidomínio (espaço de fase + wavelets) resultou em $I(\mathbf{F}_{\text{fused}}; Y) = 10{,}90$ bits, representando ganho de **73%** em discriminabilidade sobre o melhor domínio único ($I(\mathbf{F}_{\text{phase}}; Y) = 6{,}30$ bits), com peso ótimo $\alpha^* = 0{,}58$ derivado da maximização de $I(\alpha\,\mathbf{F}_{\text{phase}} + (1-\alpha)\,\mathbf{F}_{\text{wavelet}}; Y)$. **Objetivo plenamente atingido.**

8.4.4 Objetivo 4: Quantificação da Incerteza

Objetivo: Implementar um sistema de quantificação da incerteza que decomponha a incerteza epistêmica (reduzível) e a aleatória (intrínseca), fornecendo uma medida de confiabilidade para cada predição individual.

Cumprimento: O Capítulo 4, Seção 4.8, implementou a decomposição formal via conjunto *bootstrap* (Equações 8.5–8.6). A análise revelou, para o XGBoost, $\sigma^2_{\text{epistêmica}} = 0{,}0009$ (1,0%) e $\sigma^2_{\text{aleatória}} = 0{,}0908$ (99,0%), e para o Random Forest, $\sigma^2_{\text{epistêmica}} = 0{,}0012$ (14,0%) e $\sigma^2_{\text{aleatória}} = 0{,}0908$ (86,0%) (Tabela 5.9). A predominância da incerteza aleatória em ambos os modelos indica que o sistema atingiu o limite fundamental imposto pelo ruído dos dados, e não uma deficiência de modelagem. O sistema híbrido de rejeição, calibrado sobre a incerteza aleatória, alcança 100% de acurácia com 30% de rejeição (cobertura 70%), habilitando operação humano-máquina em contextos críticos de segurança. **Objetivo plenamente atingido.**

8.4.5 Objetivo 5: Validação Experimental Abrangente

Objetivo: Realizar validação experimental abrangente utilizando quatro conjuntos de dados complementares (UFPB, Fraunhofer LBF, MFPT e Paderborn), demonstrando conformidade com limites teóricos, robustez a variações operacionais extremas e desempenho estatisticamente superior aos métodos do estado da arte.

Cumprimento: Os Capítulos 5 e 6 apresentaram validação abrangente:

- **UFPB**: Acurácia 97,27%, 100% conformidade teórica, desempenho superior a 2 métodos de referência;
- **Fraunhofer**: Generalização LOBO 83,2%, robustez a 0 dB SNR (86,54%), tolerância

a 40% dados faltantes (85,34%), validação formal de caos ($p < 0,001$), vantagens estatisticamente significativas ($p < 0,005$).

8.4.6 Objetivo 6: Arcabouço de Transferibilidade Cross-Dataset

Objetivo: Desenvolver um arcabouço para quantificar e otimizar a transferibilidade entre conjuntos de dados com diferentes morfologias de defeitos, estabelecendo limites fundamentais de invariância de medição.

Cumprimento: O Capítulo 7 desenvolveu o índice MI/D_{KL} e demonstrou condicionalidade morfológica através de seis direções de transferência. A validação experimental revelou:

- Transferências A→A: 100% benéficas (2/2), ganho médio +0,005
- Transferências A→N: 50% benéficas (1/2), resultado médio -0,006
- Transferências N→A: 0% benéficas (0/2), degradação média -0,015

O método proposto (JDA-inv) alcançou superioridade ou competitividade em 4/6 direções, estabelecendo a primeira quantificação sistemática de transferibilidade morfológica na literatura.

8.5 IMPLICAÇÕES CIENTÍFICAS

As contribuições desta tese possuem implicações científicas significativas que avançam o estado da arte em diagnóstico de falhas em rolamentos e áreas correlatas:

8.5.1 Fundamentação Matemática Rigorosa

Esta tese estabelece, pela primeira vez na literatura de diagnóstico de rolamentos, **garantias matemáticas formais** para o desempenho de classificação. Enquanto trabalhos anteriores relatam acurácias empíricas sem fundamentação teórica, o arcabouço proposto fornece limites superiores verificáveis para a probabilidade de erro baseados em primeiros princípios da teoria da informação e da dinâmica não linear. Esta fundamentação permite:

- **Certificação formal** de sistemas para aplicações críticas de segurança (aeronáutica, nuclear, petroquímica);
- **Predição a priori** do desempenho mínimo garantido, dadas as características do sinal (SNR, dimensão do atrator);
- **Análise de sensibilidade** formal identificando fatores limitantes de desempenho;

- **Comparação justa** entre métodos por meio de uma referência teórica comum.

8.5.2 Unificação da Dinâmica Não Linear e Teoria da Informação

A tese demonstra que a dinâmica não linear (espaço de fase, expoentes de Lyapunov, dimensão de correlação) e a teoria da informação (entropia, informação mútua) não são abordagens disjuntas, mas **perspectivas complementares** de um mesmo problema. A integração dessas áreas por meio do arcabouço proposto:

- Fornece **interpretação física** para medidas teórico-informacionais: informação mútua quantifica a discriminabilidade de atratores no espaço de fase;
- Estabelece **conexão formal** entre complexidade dinâmica (D_2, $\lambda_{\max}$) e capacidade de canal de comunicação ($I(X;Y)$);
- Demonstra que **medidas de caos** podem ser utilizadas como **características** com fundamentação teórica e não apenas como descritores empíricos.

Esta unificação abre caminho para a aplicação de ferramentas informacional-teóricas a outros problemas de análise de sistemas dinâmicos (biomedicina, climatologia, econometria).

8.5.3 Metodologia de Validação Rigorosa

A estrutura **quádrupla** de validação — condições controladas (UFPB), aplicação industrial real (Fraunhofer), transferibilidade artificial (MFPT) e transferibilidade natural (Paderborn) — estabelece **padrão metodológico** para pesquisas futuras em diagnóstico de falhas. Enquanto grande parte da literatura valida métodos em conjuntos de dados únicos sob condições homogêneas, esta tese demonstra a importância de:

- **Validação entre conjuntos de dados** para avaliação de generalização e transferibilidade morfológica;
- **Testes de robustez** sob condições adversas (ruído, dados faltantes);
- **Validação cruzada rigorosa** (LOBO) para quantificar a variabilidade entre rolamentos;
- **Avaliação de condicionalidade morfológica** através de transferências direcionais (A$\rightarrow$A, A$\rightarrow$N, N$\rightarrow$A);
- **Comparação estatisticamente fundamentada** com testes de significância e intervalos de confiança bootstrap;

- **Validação formal de pressupostos** (testes de caos) em vez de aceitação implícita.

Este rigor metodológico eleva o nível de evidência científica na área, mitigando a ocorrência de resultados inflacionados obtidos em condições idealizadas não representativas de aplicações reais e estabelecendo, pela primeira vez, protocolos sistemáticos para avaliação de transferibilidade morfológica em diagnóstico de falhas.

8.5.4 Extensibilidade a Outros Domínios

Embora tenha sido desenvolvido para o diagnóstico de rolamentos, o arcabouço informacional-teórico proposto é **generalizável** a outros problemas de classificação de séries temporais não lineares, incluindo:

- **Diagnóstico de falhas** em outros componentes mecânicos (engrenagens, válvulas, bombas);
- **Monitoramento de saúde estrutural** (pontes, edifícios, aeronaves);
- **Análise de sinais biomédicos** (EEG, ECG, EMG para diagnóstico de patologias);
- **Detecção de anomalias** em redes de sensores e Internet das Coisas;
- **Processamento de sinais financeiros** (detecção de crises, previsão de volatilidade).

A fundamentação matemática genérica, baseada na teoria da informação e na dinâmica não linear, transcende o domínio específico de aplicação, fornecendo um arcabouço reutilizável.

8.5.5 Limites Fundamentais de Transferibilidade

O Capítulo 7 estabelece evidências de **limites fundamentais** para a transferibilidade entre conjuntos de dados em diagnóstico de falhas. A impossibilidade de um subconjunto fixo otimizar simultaneamente a transferência bidirecional sugere a existência de restrições estruturais intrínsecas ao problema.

Esta constatação possui implicações científicas amplas:

- **Projeto de características**: priorização da invariância morfológica em detrimento da discriminabilidade extrema;
- **Avaliação de métodos**: incorporação de métricas de transferibilidade como critério essencial de comparação;

- **Certificação de sistemas**: estabelecimento de protocolos para quantificação da confiabilidade sob mudança de domínio;
- **Teoria da medição**: formalização da incerteza epistêmica associada a variações morfológicas como componente irredutível do erro.

A conexão estabelecida entre a morfologia física de defeitos e a estrutura informacional de características abre uma nova linha de pesquisa na interseção entre a física de falhas e a teoria da informação.

8.6 IMPLICAÇÕES PRÁTICAS

Além das implicações científicas, esta tese possui impactos práticos significativos para a indústria e a sociedade:

8.6.1 Manutenção Preditiva Certificável

A disponibilidade de **garantias matemáticas formais** viabiliza a aplicação do arcabouço em sistemas críticos de segurança onde a certificação regulatória é mandatória. Indústrias como:

- **Aeronáutica e outras aplicações de segurança crítica**: processos de certificação e qualificação frequentemente requerem evidências robustas de confiabilidade, rastreabilidade metodológica e validação sob cenários representativos em sistemas críticos;
- **Nuclear**: NRC (*Nuclear Regulatory Commission*) exige validação matemática de sistemas de monitoramento;
- **Petroquímica**: Ambientes marítimos de alto risco necessitam de sistemas certificados para segurança operacional.

O arcabouço proposto fornece a fundamentação matemática necessária para atender a esses requisitos regulatórios, viabilizando a implementação industrial em aplicações nas quais métodos empíricos não são suficientes.

8.6.2 Redução de Custos Operacionais

A capacidade de diagnóstico precoce e confiável de falhas em rolamentos tende a produzir benefícios econômicos diretos ao reduzir a frequência e, sobretudo, a severidade de intervenções corretivas não planejadas. Em aplicações industriais, falhas de rolamentos frequentemente desencadeiam paradas imprevistas, perdas de produção, custos logísticos e,

em alguns casos, danos secundários em componentes adjacentes. Nesse contexto, um sistema de diagnóstico com desempenho robusto e medidas de confiabilidade associadas contribui para decisões de manutenção orientadas por risco.

De forma específica, destacam-se os seguintes mecanismos de redução de custo:

- **Mitigação de paradas não planejadas**: detecção antecipada aumenta a probabilidade de intervenção em janelas programadas, reduzindo perdas de produção e custos de mobilização emergencial;
- **Extensão da vida útil de componentes**: ao identificar falhas em estágio incipiente, torna-se possível intervir antes de danos secundários (por exemplo, em eixos e engrenagens), limitando o escopo da manutenção;
- **Otimização de inventário e sobressalentes**: a quantificação da incerteza fornece uma medida operacional de confiabilidade, apoiando estratégias de reposição e alocação de sobressalentes baseadas em criticidade e risco;
- **Manutenção baseada em condição**: substituições podem ser priorizadas conforme evidência diagnóstica e nível de incerteza, reduzindo intervenções preventivas excessivamente conservadoras.

Ressalta-se que a magnitude do benefício econômico é fortemente dependente do processo industrial, do regime operacional, da criticidade do ativo e do custo de parada. Por essa razão, evitam-se aqui estimativas monetárias específicas, preservando a generalidade e a rastreabilidade das conclusões apresentadas.

8.6.3 Implementação em Computação de Borda

A complexidade computacional do fluxo de processamento proposto, bem como a possibilidade de processamento em janelas temporais curtas, tornam o arcabouço compatível, em princípio, com arquiteturas de computação de borda (*edge computing*), nas quais o processamento ocorre próximo aos sensores, reduzindo latência e demanda de transmissão de dados brutos. Em termos práticos, isso pode habilitar:

- **Monitoramento quase em tempo real**: atualização de predições em janelas sucessivas, com latência limitada pelo tamanho da janela e pelo processamento local;
- **Operação sob conectividade intermitente**: execução local do diagnóstico e sincronização posterior de métricas agregadas, quando necessário;
- **Redução de tráfego de dados**: transmissão seletiva de alarmes, estatísticas e evidências diagnósticas, em vez de sinais brutos contínuos;

- **Privacidade e governança de dados**: permanência do dado sensível no ambiente local, com compartilhamento apenas de indicadores e relatórios.

Neste trabalho, a avaliação experimental foi conduzida em hardware de propósito geral. A investigação de implementações dedicadas em plataformas embarcadas e a caracterização detalhada de desempenho em dispositivos de borda constituem uma direção natural de engenharia para trabalhos futuros, sem afetar o núcleo metodológico e os resultados de validação apresentados.

8.6.4 Aplicação em Energia Renovável

A validação do arcabouço em turbinas eólicas reais (conjunto de dados Fraunhofer, 750 W) demonstra a aplicabilidade direta ao setor de energia renovável, crítico para a transição energética global. Parques eólicos típicos possuem:

- **Centenas de turbinas** em locais remotos (marítimos, montanhosos);
- **Rolamentos de alta criticidade** (por exemplo, rolamento principal e componentes da transmissão), cuja substituição envolve custos elevados, logística complexa e janelas restritas de manutenção;
- **Acessibilidade limitada** (janelas de manutenção restritas por condições climáticas);
- **Incentivos regulatórios** para maximização de disponibilidade (fator de capacidade).

A robustez demonstrada a condições adversas (variabilidade operacional, ruído, dados faltantes) torna o arcabouço particularmente adequado para este domínio de aplicação desafiador.

8.6.5 Certificação de Transferibilidade Industrial

Os resultados fornecem uma base metodológica para a **certificação de transferibilidade** em aplicações industriais. O protocolo estabelecido permite:

- **Avaliação pré-implantação**: quantificar a confiabilidade esperada de transferência entre domínios morfologicamente distintos;
- **Estratégias de aquisição de dados**: priorizar dados representativos da morfologia alvo em cenários de transferência natural→artificial;
- **Validação obrigatória**: estabelecer testes entre conjuntos de dados como requisito para implantação operacional;

- **Gestão de incerteza**: quantificar e comunicar limitações de transferibilidade para suporte à decisão.

É particularmente relevante para o setor de energia renovável, onde equipamentos são implantados globalmente em condições morfológicas variáveis (como corrosão marítima, desgaste abrasivo e fadiga térmica), mas os sistemas diagnósticos são frequentemente desenvolvidos em ambientes laboratoriais controlados

8.7 LIMITAÇÕES E TRABALHOS FUTUROS

Embora esta tese tenha estabelecido contribuições científicas e práticas significativas, reconhecem-se limitações que oferecem oportunidades para pesquisas futuras:

8.7.1 Limitações Reconhecidas

Geometrias de Rolamentos

A validação experimental foi conduzida em rolamentos rígidos de esferas (SKF 6206 e UBC 6007 2Z). A extensão para outras geometrias — como rolamentos de rolos cilíndricos, cônicos e autocompensadores de rolos — requer investigação adicional, uma vez que os padrões de contato e os mecanismos de evolução de falha diferem significativamente.

Embora a fundamentação teórica proposta seja de natureza geral, a validação experimental em geometrias adicionais é necessária para confirmar sua robustez em diferentes configurações mecânicas.

Tipos de Defeitos

Os defeitos estudados incluíram tanto defeitos artificiais localizados (corrosão por pites e descascamento superficial) induzidos de forma controlada (por descarga elétrica — EDM — e ablação a laser) quanto defeitos naturais resultantes de degradação por fadiga (conjunto Paderborn). Embora os defeitos naturais tenham fornecido validação importante da transferibilidade entre morfologias, a extensão para defeitos de campo com morfologia ainda mais irregular, progressão gradual e interação com contaminantes (e.g., água e particulados) constitui uma oportunidade para trabalhos futuros.

Estudos longitudinais que acompanhem a degradação natural desde o estágio incipiente até a falha completa forneceriam validação complementar.

Condições Operacionais

Embora o conjunto de dados Fraunhofer inclua uma turbina eólica real com variabilidade operacional, condições extremas adicionais — temperaturas extremas ($< -20\,^{\circ}\text{C}$, $> 80\,^{\circ}\text{C}$), ambientes corrosivos (marítimos) e cargas de choque (partidas e paradas bruscas) — não foram sistematicamente testadas. A validação em condições ainda mais adversas expandiria o envelope operacional demonstrado.

Escalabilidade a Múltiplos Rolamentos

A metodologia proposta requer treinamento individualizado para cada configuração de rolamento (geometria, carga, velocidade). O desenvolvimento de **modelos de transferência de aprendizado** que adaptem o conhecimento de um domínio fonte a um domínio alvo com poucos dados rotulados reduziria o custo de implementação em novas aplicações.

8.7.2 Direções para Trabalhos Futuros

Validação em Campo de Longa Duração

Estudos longitudinais monitorando rolamentos em operação industrial contínua por períodos prolongados (meses a anos) forneceriam evidências complementares de desempenho em condições não controladas. Parcerias com operadores industriais (parques eólicos, refinarias, companhias aéreas) viabilizariam a coleta de dados de degradação natural e a validação de predições de vida residual útil (RUL).

Extensão a Geometrias Adicionais

Validação sistemática em rolamentos de rolos (cilíndricos, cônicos, esféricos) e rolamentos axiais expandiria a aplicabilidade do arcabouço. Cada geometria apresenta características dinâmicas distintas (distribuição de carga, cinemática de contato) que podem requerer ajustes nos algoritmos de extração de características, mantendo a fundamentação teórica central inalterada.

Fusão com Múltiplas Modalidades de Sensores

A integração de sinais de vibração com outras modalidades — temperatura, corrente elétrica do motor, emissão acústica e análise de lubrificante — através da fusão multimodal informacional-teórica pode aumentar a robustez e a precocidade de detecção. Trabalhos futuros podem estender o arcabouço mRMR proposto para a fusão heterogênea de sensores,

explorando a complementaridade entre modalidades.

Aprendizado Contínuo e Adaptação em Linha

A implementação de mecanismos de **aprendizado contínuo**, que atualizam modelos com novos dados operacionais sem retreinamento completo, possibilitaria a adaptação a mudanças graduais nas condições operacionais (deriva de conceito). Técnicas de aprendizado incremental e online, preservando garantias teóricas, representam uma direção promissora.

Implementação em Hardware Embarcado Otimizado

Exploração de aceleradores de hardware especializados — FPGAs, ASICs, computação neuromórfica — para a implementação ultra-eficiente dos algoritmos propostos pode reduzir o consumo energético e a latência, viabilizando a aplicação em dispositivos da Internet das Coisas com restrições severas de energia (sensores alimentados por coleta de energia).

Extensão a Outros Componentes Mecânicos

A aplicação da metodologia teórico-informacional ao diagnóstico de falhas em engrenagens, válvulas, bombas e compressores exploraria a generalidade do arcabouço. Cada domínio apresenta características específicas (modulação de amplitude e frequência em engrenagens, cavitação em bombas) que podem se beneficiar da adaptação do arcabouço, mantendo o núcleo teórico.

Integração com Gêmeos Digitais

O desenvolvimento de **gêmeos digitais** que integrem um modelo físico (simulação multicorpos da dinâmica de rolamentos) com um arcabouço baseado em dados proposto permitiria a síntese de dados sintéticos para treinamento, a simulação de cenários de falhas raras e a otimização do projeto de sistemas rotativos para diagnosticabilidade.

Transferibilidade Multidirecional Ótima

Desenvolvimento de algoritmos que computem subconjuntos invariantes otimizados simultaneamente para múltiplas direções de transferência, resolvendo a limitação da assimetria N→A identificada. Técnicas de otimização multiobjetivo e teoria de jogos podem fornecer fundamentação matemática para esse problema.

Taxonomia Morfológica Expandida

Criação de uma taxonomia sistemática de morfologias de defeitos baseada em propriedades físicas mensuráveis (rugosidade, geometria, progressão temporal), estabelecendo métricas quantitativas de distância morfológica para predição a priori de transferibilidade.

Transferibilidade Hierárquica

Investigação de transferibilidade em múltiplos níveis hierárquicos: intra-geometria (diferentes tamanhos do mesmo tipo), inter-geometria (diferentes tipos de rolamentos), inter-componente (rolamentos para engrenagens) e inter-sistema (diferentes máquinas rotativas).

8.8 CONSIDERAÇÕES FINAIS

Esta tese desenvolveu um arcabouço teórico–informacional matematicamente fundamentado para o diagnóstico de falhas em rolamentos, integrando dinâmica não linear, teoria da informação e aprendizado de máquina. As contribuições centrais incluem a derivação de limites fundamentais de desempenho, a otimização informacional de parâmetros dinâmicos, a fusão multidomínio baseada em relevância e redundância e a quantificação formal da incerteza associada às predições.

A validação experimental, conduzida por meio de uma estrutura **tripla** que combina condições controladas (UFPB), robustez industrial (Fraunhofer) e **transferibilidade entre conjuntos de dados** (MFPT, Paderborn, LBF), demonstrou que o desempenho alcançado pelo arcabouço proposto é compatível com a capacidade informacional disponível nos sinais analisados, respeitando limites fundamentais impostos pela teoria da informação e pela heterogeneidade morfológica dos defeitos.

Esses resultados indicam que um diagnóstico confiável de falhas em rolamentos não exige a escolha entre rigor matemático, desempenho prático e **transferibilidade entre domínios**. Ao integrar dinâmica não linear, teoria da informação, aprendizado de máquina e **invariância de medição**, é possível desenvolver sistemas com desempenho robusto, interpretabilidade e garantias formais de confiabilidade sob mudança de domínio.

REFERÊNCIAS

ABOY, M. *et al.* Interpretation of the Lempel-Ziv Complexity Measure in the Context of Biomedical Signal Analysis. **IEEE Transactions on Biomedical Engineering**, v. 53, n. 11, p. 2282–2288, 2006. DOI: 10.1109/TBME.2006.883696.

ADDISON, P. S. **The Illustrated Wavelet Transform Handbook: Introductory Theory and Applications in Science, Engineering, Medicine and Finance**. Bristol: Institute of Physics Publishing, 2002.

ALEXAKOS, Christos T. *et al.* A Combined Short Time Fourier Transform and Image Classification Transformer Model for Rolling Element Bearings Fault Diagnosis in Electric Motors. **Machine Learning and Knowledge Extraction**, v. 3, n. 1, p. 228–242, 2021. ISSN 2504-4990. DOI: 10.3390/make3010011.

ALMEIDA, Paulo R. L.; LIMA, Thyago L. V.; BRITO, Alisson V.; FILHO, Abel C. Lima. Validated chaos theory for robust bearing fault diagnosis. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, Springer, v. 48, n. 4, p. 302, mar. 2026. ISSN 1806-3691. DOI: 10.1007/s40430-026-06390-x. Disponível em: https://doi.org/10.1007/s40430-026-06390-x.

ALMEIDA, Paulo R. L.; LIMA, Thyago L. V.; BRITO, Alisson V.; LIMA-FILHO, Abel C. Optimal feature complexity for small-sample bearing fault detection in manufacturing. **The International Journal of Advanced Manufacturing Technology**, dez. 2025. ISSN 1433-3015. DOI: 10.1007/s00170-025-17296-8.

ALMEIDA, Paulo R.L.; LIMA, Thyago L.V.; BRITO, Alisson V.; FILHO, Abel C. Lima. Bearing fault diagnosis via topological data analysis: Strategic feature selection and algorithm-dependent performance under sample-size constraints. **Mechanical Systems and Signal Processing**, v. 250, p. 114103, 2026. ISSN 0888-3270. DOI: 10.1016/j.ymssp.2026.114103.

ALMEIDA, Paulo R.L.; LIMA, Thyago L.V.; BRITO, Alisson V.; LIMA FILHO, Abel C. Multifractal characterization of bearing fault progression: Persistent-to-anti-persistent dynamics transition and cross-dataset validation of complexity-based features. **Chaos, Solitons & Fractals**, v. 206, p. 117909, 2026. ISSN 0960-0779. DOI: 10.1016/j.chaos.2026.117909. Disponível em: https://www.sciencedirect.com/science/article/pii/S0960077926000500.

ALMEIDA, Paulo R.L.; LIMA, Thyago L.V.; BRITO, Alisson V.; LIMA-FILHO, Abel C. Information-theoretic bearing fault diagnosis with nonlinear dynamics analysis and theoretical performance bounds. **Measurement**, v. 262, p. 119995, 2026. ISSN 0263-2241. DOI: 10.1016/j.measurement.2025.119995.

AMARI, S.; NAGAOKA, H. **Methods of Information Geometry**. [*S. l.*]: American Mathematical Society, 2000. (Translations of mathematical monographs). ISBN 9780821843024. Disponível em: https://books.google.com.br/books?id=vc2FWSo7wLUC.

ANBALAGAN, Sriram; NATARAJAN, Balasubramaniam; SRINIVASAN, Babji. A Physics Based Deep Learning Approach for Cross Domain Bearing Fault Detection. *In:* IEEE. 2023 IEEE Kansas Power and Energy Conference (KPEC). [*S. l.: s. n.*], abr. 2023. p. 1–4. DOI: 10.1109/kpec58008.2023.10215413.

BANDT, Christoph; POMPE, Bernd. Permutation Entropy: A Natural Complexity Measure for Time Series. **Physical Review Letters**, v. 88, n. 17, p. 174102, 2002. DOI: 10.1103/PhysRevLett.88.174102.

BAZAN, Gustavo Henrique *et al.* Information Theoretical Measurements From Induction Motors Under Several Load and Voltage Conditions for Bearing Faults Classification. **IEEE Transactions on Industrial Informatics**, v. 16, n. 6, p. 3640–3650, 2020. DOI: 10.1109/TII.2019.2939678.

BECHHOEFER, Eric. Condition based maintenance fault database for testing diagnostics and prognostic algorithms. **MFPT Data**, 2013.

BEN-DAVID, Shai *et al.* Analysis of Representations for Domain Adaptation. *In:* SCHÖLKOPF, B.; PLATT, J.; HOFFMAN, T. (ed.). **Advances in Neural Information Processing Systems**. [*S. l.*]: MIT Press, 2006. v. 19. Disponível em: https://proceedings.neurips.cc/paper_files/paper/2006/file/b1b0432ceafb0ce714426e9114852ac7-Paper.pdf.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001.

CATONI, Olivier. **PAC-Bayesian Supervised Classification: The Thermodynamics of Statistical Learning**. Beachwood, OH: Institute of Mathematical Statistics, 2007. v. 56, p. 163. (IMS Lecture Notes Monograph Series). ISBN 0-940600-72-2.

CHEN, T.; GUESTRIN, C. XGBoost: A scalable tree boosting system. *In:* PROCEEDINGS of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco, CA: [*s. n.*], ago. 2016. p. 785–794.

CHEN, X.; ZHANG, B.; GAO, D. Deep transfer learning for bearing fault diagnosis: A systematic review since 2016. **IEEE Transactions on Instrumentation and Measurement**, v. 73, p. 1–21, 2024.

CHEN, Xiaohan *et al.* Transfer Learning with Unsupervised Domain Adaptation Method for Bearing Fault Diagnosis. *In:* IEEE. 2021 CAA Symposium on Fault Detection, Supervision, and Safety for Technical Processes (SAFEPROCESS). [*S. l.: s. n.*], dez. 2021. p. 1–6. DOI: 10.1109/safeprocess52771.2021.9693742.

CHEN, Zhuyun *et al.* A deep learning method for bearing fault diagnosis based on Cyclic Spectral Coherence and Convolutional Neural Networks. **Mechanical Systems and Signal Processing**, v. 140, p. 106683, 2020. ISSN 0888-3270. DOI: doi.org/10.1016/j.ymssp.2020.106683.

CHENNANA, Ahmed *et al.* Vibration signal analysis for rolling bearings faults diagnosis based on deep-shallow features fusion. **Scientific Reports**, Springer Science and Business Media LLC, v. 15, n. 1, mar. 2025. ISSN 2045-2322. DOI: 10.1038/s41598-025-93133-y.

COHEN, Leon. **Time-Frequency Analysis**. Englewood Cliffs, NJ: Prentice Hall, 1995. ISBN 0135945321.

COVER, T. M.; THOMAS, J. A. **Elements of Information Theory**. 2. ed. Hoboken, NJ: Wiley-Interscience, 2006.

DAUBECHIES, Ingrid; HEIL, Christopher. Ten Lectures on Wavelets. **Computer in Physics**, v. 6, n. 6, p. 697–697, nov. 1992. ISSN 0894-1866. DOI: 10.1063/1.4823127.

DEMBO, A.; COVER, T.M.; THOMAS, J.A. Information theoretic inequalities. **IEEE Transactions on Information Theory**, v. 37, n. 6, p. 1501–1518, 1991. DOI: 10.1109/18.104312.

ECKMANN, J.-P.; KAMPHORST, S. O.; RUELLE, D. Recurrence plots of dynamical systems. **Europhysics Letters**, v. 4, n. 9, p. 973–977, 1987.

EFRON, B.; TIBSHIRANI, R. J. **An Introduction to the Bootstrap**. Boca Raton, FL: Chapman & Hall/CRC, 1994.

FRASER, A. M.; SWINNEY, H. L. Independent coordinates for strange attractors from mutual information. **Physical Review A**, v. 33, n. 2, p. 1134–1140, 1986.

FRIEDMAN, Jerome H. Greedy function approximation: A gradient boosting machine. **Annals of Statistics**, Institute of Mathematical Statistics, v. 29, n. 5, p. 1189–1232, 2001. DOI: 10.1214/aos/1013203451.

GAL, Yarin; GHAHRAMANI, Zoubin. Dropout as a Bayesian Approximation: Representing Model Uncertainty in Deep Learning. *In:* PROCEEDINGS of the 33rd International Conference on Machine Learning. New York, NY, USA: PMLR, jun. 2016. v. 48. (Proceedings of Machine Learning Research), p. 1050–1059. Disponível em: http://proceedings.mlr.press/v48/gal16.html.

GOWER, John C; DIJKSTERHUIS, Garmt B. **Procrustes Problems**. [*S. l.*]: Oxford University Press, jan. 2004. ISBN 9780198510581. DOI: 10.1093/acprof:oso/9780198510581.001.0001.

GRASSBERGER, P.; PROCACCIA, I. Measuring the strangeness of strange attractors. **Physica D: Nonlinear Phenomena**, v. 9, n. 1-2, p. 189–208, 1983.

GRAY, Robert M. **Entropy and Information Theory**. 2. ed. New York: Springer, 2011.

GRINSTED, A.; MOORE, J. C.; JEVREJEVA, S. Application of the cross wavelet transform and wavelet coherence to geophysical time series. **Nonlinear Processes in Geophysics**, v. 11, n. 5/6, p. 561–566, 2004.

GUO, Chaochao *et al.* Deep Causal Disentanglement Network With Domain Generalization for Cross-Machine Bearing Fault Diagnosis. **IEEE Transactions on Instrumentation and Measurement**, Institute of Electrical and Electronics Engineers (IEEE), v. 74, p. 1–16, 2025. ISSN 0018-9456. DOI: 10.1109/tim.2025.3545703.

GUO, Chenxi *et al.* MDFT-GAN: A Multi-Domain Feature Transformer GAN for Bearing Fault Diagnosis Under Limited and Imbalanced Data Conditions. **Applied Sciences**, MDPI AG, v. 15, n. 11, p. 6225, maio 2025. ISSN 2076-3417. DOI: 10.3390/app15116225.

HARRIS, T. A.; KOTZALAS, M. N. **Rolling Bearing Analysis**. 5. ed. Boca Raton, FL: CRC Press, 2006.

HU, Qin *et al.* Balanced Adaptation Regularization Based Transfer Learning for Unsupervised Cross-Domain Fault Diagnosis. **IEEE Sensors Journal**, v. 22, n. 12, p. 12139–12151, 2022. DOI: 10.1109/JSEN.2022.3174396.

HÜLLERMEIER, Eyke; WAEGEMAN, Willem. Aleatoric and Epistemic Uncertainty in Machine Learning: An Introduction to Concepts and Methods. **Machine Learning**, Springer, v. 110, n. 3, p. 457–506, 2021. DOI: 10.1007/s10994-021-05946-3.

JOHNSON, K. L. **Contact Mechanics**. Cambridge: Cambridge University Press, 1985.

JOSHI, Ishan; CHAUDHARY, Aayushi; THAKUR, Arjun. A Review – BearMath: Bearing Fault Diagnostics Using Machine Learning. **International Journal for Multidisciplinary Research**, International Journal for Multidisciplinary Research (IJFMR), v. 7, n. 2, 2025. ISSN 2582-2160. DOI: 10.36948/ijfmr.2025.v07i02.39641.

KANTZ, H.; SCHREIBER, T. **Nonlinear Time Series Analysis**. 2. ed. Cambridge: Cambridge University Press, 2004.

KAPLAN, James L.; YORKE, James A. Chaotic Behavior of Multidimensional Difference Equations. *In:* FUNCTIONAL Differential Equations and Approximation of Fixed Points. Berlin: Springer, 1979. v. 730. (Lecture Notes in Mathematics). p. 204–227.

KASPAR, F.; SCHUSTER, H. G. Easily calculable measure for the complexity of spatiotemporal patterns. **Phys. Rev. A**, American Physical Society, v. 36, p. 842–848, 2 jul. 1987. DOI: 10.1103/PhysRevA.36.842.

KENDALL, A.; GAL, Y. What uncertainties do we need in Bayesian deep learning for computer vision? *In:* ADVANCES in Neural Information Processing Systems 30 (NIPS 2017). Long Beach, CA: [*s. n.*], dez. 2017. p. 5574–5584.

KENNEL, M. B.; BROWN, R.; ABARBANEL, H. D. I. Determining embedding dimension for phase-space reconstruction using a geometrical construction. **Physical Review A**, v. 45, n. 6, p. 3403–3411, 1992.

KIM, Iljeok *et al.* Single domain generalizable and physically interpretable bearing fault diagnosis for unseen working conditions. **Expert Systems with Applications**, Elsevier BV, v. 241, p. 122455, maio 2024. ISSN 0957-4174. DOI: 10.1016/j.eswa.2023.122455.

KOHAVI, Ron. A study of cross-validation and bootstrap for accuracy estimation and model selection. **International Joint Conference on Artificial Intelligence**, Morgan Kaufmann Publishers Inc., Montreal, Quebec, Canada, v. 2, p. 1137–1143, 1995.

KRAEMER, K. Hauke *et al.* Recurrence threshold selection for obtaining robust recurrence characteristics in different embedding dimensions. **Chaos: An Interdisciplinary Journal of Nonlinear Science**, v. 28, n. 8, p. 085720, ago. 2018. ISSN 1054-1500. DOI: 10.1063/1.5024914.

KRASKOV, Alexander; STÖGBAUER, Harald; GRASSBERGER, Peter. Estimating mutual information. **Phys. Rev. E**, American Physical Society, v. 69, p. 066138, 6 jun. 2004. DOI: 10.1103/PhysRevE.69.066138.

LAKSHMINARAYANAN, Balaji; PRITZEL, Alexander; BLUNDELL, Charles. Simple and Scalable Predictive Uncertainty Estimation using Deep Ensembles. *In:* GUYON, I. *et al.* (ed.). **Advances in Neural Information Processing Systems**. Red Hook, NY, USA: Curran Associates, Inc., 2017. v. 30. (NIPS'17), p. 6405–6416. ISBN 9781510860964.

LEI, Tongfei *et al.* A fault diagnosis method for rolling bearings in open-set domain adaptation with adversarial learning. **Scientific Reports**, Nature Publishing Group, v. 15, n. 1, p. 10793, mar. 2025. ISSN 2045-2322. DOI: 10.1038/s41598-025-88353-1.

LEI, Y. *et al.* A review on empirical mode decomposition in fault diagnosis of rotating machinery. **Mechanical Systems and Signal Processing**, v. 35, n. 1-2, p. 108–126, 2013.

LEMPEL, A.; ZIV, J. On the Complexity of Finite Sequences. **IEEE Transactions on Information Theory**, v. 22, n. 1, p. 75–81, 1976. DOI: 10.1109/TIT.1976.1055501.

LESSMEIER, Christian *et al.* Condition monitoring of bearing damage in electromechanical drive systems by using motor current signals of electric motors: A benchmark data set for data-driven classification. *In:* EUROPEAN conference of the prognostics and health management society. [*S. l.: s. n.*], 2016. p. 05–08.

LI, Yongbo *et al.* Entropy Based Fault Classification Using the Case Western Reserve University Data: A Benchmark Study. **IEEE Transactions on Reliability**, v. 69, n. 2, p. 754–767, 2020. DOI: 10.1109/TR.2019.2896240.

LONG, Mingsheng *et al.* Transfer Feature Learning with Joint Distribution Adaptation. *In:* 2013 IEEE International Conference on Computer Vision. [*S. l.: s. n.*], 2013. p. 2200–2207. DOI: 10.1109/ICCV.2013.274.

MALLAT, S. **A Wavelet Tour of Signal Processing: The Sparse Way**. 3. ed. Burlington, MA: Academic Press, 2009.

MARAGOS, P.; SCHAFER, R. Morphological filters–Part I: Their set-theoretic analysis and relations to linear shift-invariant filters. **IEEE Transactions on Acoustics, Speech, and Signal Processing**, v. 35, n. 8, p. 1153–1169, 1987. DOI: 10.1109/TASSP.1987.1165259.

MARWAN, N. *et al.* Recurrence plots for the analysis of complex systems. **Physics Reports**, v. 438, n. 5-6, p. 237–329, 2007. DOI: 10.1016/j.physrep.2006.11.001.

MATHERON, Georges. **Random Sets and Integral Geometry**. [*S. l.*]: John Wiley & Sons, 1975.

MCALLESTER, David A. PAC-Bayesian model averaging. *In:* PROCEEDINGS of the Twelfth Annual Conference on Computational Learning Theory. Santa Cruz, CA, USA: ACM, 1999. p. 164–170. DOI: 10.1145/307400.307435.

MCFADDEN, P. D.; SMITH, J. D. Model for the vibration produced by a single point defect in a rolling element bearing. **Journal of Sound and Vibration**, v. 96, n. 1, p. 69–82, 1984.

MINHAS, Amrinder Singh *et al.* Bearing fault detection and recognition methodology based on weighted multiscale entropy approach. **Mechanical Systems and Signal Processing**, v. 147, p. 107073, 2021. ISSN 0888-3270. DOI: 10.1016/j.ymssp.2020.107073.

MOBLEY, R. K. **An Introduction to Predictive Maintenance**. 2. ed. Oxford: Butterworth-Heinemann, 2002.

MOSTAFAVI, Amirhossein; FRIEDMANN, Alexander. Wind turbine condition monitoring dataset of Fraunhofer LBF. **Scientific Data**, v. 11, p. 1108, 2024. DOI: 10.1038/s41597-024-03934-5.

NAJDI, Boubker; BENBRAHIM, Mohammed; KABBAJ, Mohammed Nabil. Bearing Fault Diagnosis under Varying Work Conditions Based on Synchrosqueezing Transform, Random Projection, and Convolutional Neural Networks. **International Journal of Prognostics and Health Management**, PHM Society, v. 15, n. 1, mar. 2024. ISSN 2153-2648. DOI: 10.36001/ijphm.2024.v15i1.3799.

NIKOLAOU, N.G.; ANTONIADIS, I.A. Rolling element bearing fault diagnosis using wavelet packets. **NDT & E International**, v. 35, n. 3, p. 197–205, 2002. ISSN 0963-8695. DOI: 10.1016/S0963-8695(01)00044-5.

PALAIOLOGOU, Ilias *et al.* Enhancing machine learning multi-class fault detection in electric motors through entropy-based analysis. **Measurement Science and Technology**, IOP Publishing, v. 36, n. 1, p. 016111, out. 2024. DOI: 10.1088/1361-6501/ad8471.

PAN, Sinno Jialin *et al.* Domain Adaptation via Transfer Component Analysis. **IEEE Transactions on Neural Networks**, v. 22, n. 2, p. 199–210, 2011. DOI: 10.1109/TNN.2010.2091281.

PATEL, V. N.; UPADHYAY, N.; HARSHA, S. P. Nonlinear dynamic response of cylindrical roller bearing-rotor system with 9 degree of freedom model. **Tribology in Industry**, v. 32, n. 3, p. 3–15, 2010.

PENG, Hanchuan; LONG, Fuhui; DING, Chris. Feature Selection Based on Mutual Information: Criteria of Max-Dependency, Max-Relevance, and Min-Redundancy. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 27, n. 8, p. 1226–1238, 2005. DOI: 10.1109/TPAMI.2005.159.

PENG, Z. K.; CHU, F. L. Application of the wavelet transform in machine condition monitoring and fault diagnostics: A review with bibliography. **Mechanical Systems and Signal Processing**, v. 18, n. 2, p. 199–221, 2004.

PESIN, Yakov B. Characteristic Lyapunov Exponents and Smooth Ergodic Theory. **Russian Mathematical Surveys**, v. 32, n. 4, p. 55–114, 1977.

PINCUS, S. M. Approximate entropy as a measure of system complexity. **Proceedings of the National Academy of Sciences**, v. 88, n. 6, p. 2297–2301, 1991.

QIU, Wentao; WANG, Bing; HU, Xiong. Rolling bearing fault diagnosis based on RQA with STD and WOA-SVM. **Heliyon**, Elsevier, v. 10, n. 4, e26141, 2024. ISSN 2405-8440. DOI: 10.1016/j.heliyon.2024.e26141.

RAJ, A. Santhana; MURALI, N. Early Classification of Bearing Faults Using Morphological Operators and Fuzzy Inference. **IEEE Transactions on Industrial Electronics**, v. 60, n. 2, p. 567–574, 2013. DOI: 10.1109/TIE.2012.2188259.

RANDALL, R. B.; ANTONI, J. Rolling element bearing diagnostics—A tutorial. **Mechanical Systems and Signal Processing**, v. 25, n. 2, p. 485–520, 2011.

RICHMAN, J. S.; MOORMAN, J. R. Physiological time-series analysis using approximate entropy and sample entropy. **American Journal of Physiology-Heart and Circulatory Physiology**, v. 278, n. 6, h2039–h2049, 2000.

RONG, Zhicong; LEE, Jihyun. An interpretable transfer learning method for bearing diagnosis across different systems, faults, and signal types. **Structural Health Monitoring**, SAGE Publications, set. 2025. ISSN 1475-9217. DOI: 10.1177/14759217251363600.

SERRA, Jean. **Image Analysis and Mathematical Morphology**. [*S. l.*]: Academic Press, 1982.

SHALEV-SHWARTZ, Shai; BEN-DAVID, Shai. **Understanding Machine Learning: From Theory to Algorithms**. Cambridge: Cambridge University Press, 2014. p. 410. ISBN 978-1-107-05713-5.

SHANNON, C. E. A mathematical theory of communication. **Bell System Technical Journal**, v. 27, n. 3, p. 379–423, 1948.

SHARMA, Aditya. Fault diagnosis of bearings using recurrences and AI techniques. **Journal of Nondestructive Evaluation, Diagnostics and Prognostics of Engineering Systems**, 2022. DOI: 10.1115/1.4053773.

SINGH, Abhishek Anand *et al.* A multi-entropy fusion approach for rolling bearing fault diagnosis integrated with variational mode decomposition. *In:* 2021 8th International Conference on Signal Processing and Integrated Networks (SPIN). [*S. l.: s. n.*], 2021. p. 367–372. DOI: 10.1109/SPIN52536.2021.9566100.

SMITH, W. A.; RANDALL, R. B. Rolling element bearing diagnostics using the Case Western Reserve University data: A benchmark study. **Mechanical Systems and Signal Processing**, v. 64-65, p. 100–131, 2015.

SONG, Renwang *et al.* Bearing Fault Diagnosis Method Based on Multidomain Heterogeneous Information Entropy Fusion and Model Self-Optimisation. **Shock and Vibration**, v. 2022, n. 1, p. 7214822, 2022. DOI: 10.1155/2022/7214822.

STROGATZ, S. H. **Nonlinear Dynamics and Chaos: With Applications to Physics, Biology, Chemistry, and Engineering**. 2. ed. Boulder, CO: Westview Press, 2015.

SUN, Baochen; SAENKO, Kate. Deep CORAL: Correlation Alignment for Deep Domain Adaptation. *In:* HUA, Gang; JÉGOU, Hervé (ed.). **Computer Vision – ECCV 2016 Workshops**. Cham: Springer International Publishing, 2016. p. 443–450. ISBN 978-3-319-49409-8.

TAKENS, F. Detecting strange attractors in turbulence. *In:* RAND, D.; YOUNG, L.-S. (ed.). **Dynamical Systems and Turbulence, Lecture Notes in Mathematics**. Berlin: Springer-Verlag, 1981. v. 898. p. 366–381.

TANDON, N.; CHOUDHURY, A. A review of vibration and acoustic measurement methods for the detection of defects in rolling element bearings. **Tribology International**, v. 32, n. 8, p. 469–480, 1999.

THEILER, James. Efficient Algorithm for Estimating the Correlation Dimension from a Set of Discrete Points. **Physical Review A**, v. 36, n. 9, p. 4456–4462, 1987. DOI: 10.1103/PhysRevA.36.4456.

TSYBAKOV, Alexandre B. **Introduction to Nonparametric Estimation**. New York: Springer, 2009. ISBN 9780387790510.

VAPNIK, Vladimir N. **Statistical Learning Theory**. New York: Wiley, 1998. p. 768. ISBN 978-0-471-03003-4.

VAPNIK, Vladimir N. **The Nature of Statistical Learning Theory**. 2nd. New York: Springer, 2000. p. 314. ISBN 978-0-387-98780-4.

VAPNIK, Vladimir N.; CHERVONENKIS, Alexey Y. On the uniform convergence of relative frequencies of events to their probabilities. **Theory of Probability & Its Applications**, SIAM, v. 16, n. 2, p. 264–280, 1971. DOI: 10.1137/1116025.

VOVK, Vladimir; GAMMERMAN, Alex; SHAFER, Glenn. Algorithmic Learning in a Random World. **Springer**, New York, NY, 2022. DOI: 10.1007/978-3-031-06649-8.

WANG, Bing *et al.* A rolling bearing fault diagnosis technique based on recurrence quantification analysis and Bayesian optimization SVM. **Applied Soft Computing**, v. 156, p. 111506, 2024. ISSN 1568-4946. DOI: 10.1016/j.asoc.2024.111506.

WANG, Dong; TSE, Peter W.; TSUI, Kwok Leung. An enhanced Kurtogram method for fault diagnosis of rolling element bearings. **Mechanical Systems and Signal Processing**, v. 35, n. 1–2, p. 176–199, 2012. DOI: 10.1016/j.ymssp.2012.10.003.

WANG, Shanshan *et al.* A Domain Adaptation Meta Learning Method With Multilayer Convolutional Attention for Cross-Domain Bearing Fault Diagnosis. **IEEE Sensors Journal**, 2025. DOI: 10.1109/JSEN.2025.3546955.

WANG, Shun *et al.* Cumulative spectrum distribution entropy for rotating machinery fault diagnosis. **Mechanical Systems and Signal Processing**, v. 206, p. 110905, 2024. ISSN 0888-3270. DOI: 10.1016/j.ymssp.2023.110905.

WOLF, A. *et al.* Determining Lyapunov exponents from a time series. **Physica D: Nonlinear Phenomena**, v. 16, n. 3, p. 285–317, 1985.

WU, Shiqian *et al.* ACMSlE: A Novel Framework for Rolling Bearing Fault Diagnosis. **Processes**, v. 13, n. 4, 2025. ISSN 2227-9717. DOI: 10.3390/pr13041167.

XIAO, Yang *et al.* Cross-Domain Diagnostic Method of Rolling Bearings Based on Refined Composite Zoom Multiscale Weighted Permutation Entropy-Ensemble Feature Transfer Learning. **IEEE Transactions on Instrumentation and Measurement**, v. 74, p. 1–22, 2025. DOI: 10.1109/TIM.2025.3545507.

YAN, Ruqiang; GAO, Robert X. Complexity as a Measure for Machine Health Evaluation. **IEEE Transactions on Instrumentation and Measurement**, v. 61, n. 10, p. 2636–2644, 2012. DOI: 10.1109/TIM.2012.2196390.

ZHANG, Benjie; WANG, Wei; HE, Yan. A hybrid approach combining deep learning and signal processing for bearing fault diagnosis under imbalanced samples and multiple operating conditions. **Scientific Reports**, 2025. DOI: 10.1038/s41598-025-98138-1.

ZHANG, Bo; LI, Feixuan *et al.* Open Set Bearing Fault Diagnosis with Domain Adaptive Adversarial Network under Varying Conditions. **Actuators**, MDPI AG, v. 13, n. 4, p. 121, mar. 2024. ISSN 2076-0825. DOI: 10.3390/act13040121.

ZHOU, Junbo *et al.* Rolling Bearing Fault Diagnosis Based on WGWOA-VMD-SVM. **Sensors**, v. 22, n. 16, 2022. ISSN 1424-8220. DOI: 10.3390/s22166281.

APÊNDICE A

DEDUÇÕES MATEMÁTICAS E DEMONSTRAÇÕES AUXILIARES

Este apêndice apresenta as deduções matemáticas detalhadas e demonstrações de proposições utilizadas ao longo da tese, fornecendo rigor técnico sem interromper o fluxo narrativo dos capítulos principais.

A.1 DEDUÇÃO DOS LIMITES TEÓRICO-INFORMACIONAIS DE FANO

A.1.1 Demonstração da Desigualdade de Fano para Classificação Multi-classe

Considere um sistema de classificação com K classes possíveis $\mathcal{Y} = \{y_1, y_2, \ldots, y_K\}$. Sejam Y a variável aleatória que representa a classe verdadeira e $\hat{Y} = g(X)$ a classe predita por um classificador determinístico baseado nas observações X. A probabilidade de erro de classificação é definida como

$$P_e = P(\hat{Y} \neq Y). \tag{A.1}$$

Teorema (Desigualdade de Fano). Para qualquer classificador determinístico $\hat{Y} = g(X)$, vale:

$$H(Y|X) \leq H(P_e) + P_e \log_2(K-1), \tag{A.2}$$

onde $H(P_e) = -P_e \log_2 P_e - (1-P_e)\log_2(1-P_e)$ é a entropia binária.

Demonstração:

Passo 1: Variável indicadora de erro. Defina a variável aleatória binária

$$E = \begin{cases} 0, & \text{se } \hat{Y} = Y, \\ 1, & \text{se } \hat{Y} \neq Y. \end{cases} \tag{A.3}$$

Passo 2: Regra da cadeia da entropia. Aplicando a regra da cadeia:

$$H(Y, E|X) = H(E|X) + H(Y|E, X). \tag{A.4}$$

Passo 3: Relação entre $H(Y, E|X)$ e $H(Y|X)$. Como $\hat{Y}$ é função determinística de X, a variável E é função determinística do par (Y, X). Logo,

$$H(E|Y, X) = 0, \tag{A.5}$$

e, portanto,

$$H(Y, E|X) = H(Y|X). \tag{A.6}$$

Passo 4: Limitação de $H(E|X)$. Como E é binária:

$$H(E|X) \leq H(E) = H(P_e). \tag{A.7}$$

Passo 5: Limitação de $H(Y|E, X)$. Condicionando em E:

$$H(Y|E, X) = P(E = 0)H(Y|E = 0, X) + P(E = 1)H(Y|E = 1, X). \tag{A.8}$$

Para classificadores determinísticos, $E = 0$ implica $Y = \hat{Y}(X)$, logo $H(Y|E = 0, X) = 0$. Quando $E = 1$, o valor verdadeiro de Y pertence a, no máximo, $K - 1$ classes possíveis, de modo que

$$H(Y|E = 1, X) \leq \log_2(K - 1). \tag{A.9}$$

Assim,

$$H(Y|E, X) \leq P_e \log_2(K - 1). \tag{A.10}$$

Passo 6: Combinação dos resultados. Substituindo nos passos anteriores:

$$H(Y|X) \leq H(P_e) + P_e \log_2(K - 1). \tag{A.11}$$

□

A.1.2 Limite Inferior para a Probabilidade de Erro

A partir da desigualdade de Fano, obtém-se o seguinte limite inferior clássico para a probabilidade de erro:

$$P_e \geq \frac{H(Y|X) - 1}{\log_2 K}, \tag{A.12}$$

válido para $K \geq 2$.

Para o problema de diagnóstico de rolamentos com $K = 4$ classes (saudável, pista

interna, pista externa e elemento rolante),

$$P_e \geq \frac{H(Y|X) - 1}{\log_2 4} = \frac{H(Y|X) - 1}{2}. \tag{A.13}$$

Interpretação física: Este limite estabelece um compromisso fundamental entre a informação mútua $I(X;Y) = H(Y) - H(Y|X)$ e a acurácia de classificação. Para que $P_e \to 0$, é necessário que $H(Y|X) \to 0$, ou, equivalentemente, que a representação extraída preserve quase toda a informação relevante da classe, isto é, $I(X;Y) \to H(Y)$.

A.2 DEMONSTRAÇÃO DAS PROPRIEDADES DO EXPOENTE DE LYAPUNOV

A.2.1 Invariância do Maior Expoente de Lyapunov sob Mudança de Coordenadas

Proposição. O maior expoente de Lyapunov $\lambda_{\max}$ é invariante sob mudanças de coordenadas suaves e invertíveis (C^1-difeomorfismos).

Demonstração:

Considere um sistema dinâmico contínuo $\dot{\mathbf{x}} = \mathbf{f}(\mathbf{x})$ com fluxo ϕ_t. O expoente de Lyapunov associado a uma perturbação infinitesimal $\delta\mathbf{x}(t)$ é definido como

$$\lambda_x = \lim_{t\to\infty} \frac{1}{t} \log \frac{\|\delta\mathbf{x}(t)\|}{\|\delta\mathbf{x}(0)\|}. \tag{A.14}$$

Considere uma mudança de coordenadas suave e invertível $\mathbf{y} = \mathbf{g}(\mathbf{x})$, com Jacobiano $J(\mathbf{x}) = \partial\mathbf{g}/\partial\mathbf{x}$. A perturbação no novo sistema satisfaz

$$\delta\mathbf{y}(t) = J(\mathbf{x}(t))\, \delta\mathbf{x}(t). \tag{A.15}$$

Como $\mathbf{g}$ é um difeomorfismo, J e J^{-1} são limitados. Assim, existem constantes $0 < c_1 < c_2 < \infty$ tais que

$$c_1\|\delta\mathbf{x}\| \leq \|\delta\mathbf{y}\| \leq c_2\|\delta\mathbf{x}\|. \tag{A.16}$$

Logo,

$$\lambda_y = \lim_{t\to\infty} \frac{1}{t} \log \frac{\|\delta \mathbf{y}(t)\|}{\|\delta \mathbf{y}(0)\|} \tag{A.17}$$

$$\leq \lim_{t\to\infty} \frac{1}{t} \log \frac{c_2 \|\delta \mathbf{x}(t)\|}{c_1 \|\delta \mathbf{x}(0)\|} \tag{A.18}$$

$$= \lambda_x + \lim_{t\to\infty} \frac{\log(c_2/c_1)}{t} = \lambda_x. \tag{A.19}$$

Aplicando o mesmo argumento à transformação inversa $\mathbf{x} = \mathbf{g}^{-1}(\mathbf{y})$, obtém-se $\lambda_x \leq \lambda_y$. Portanto,

$$\lambda_x = \lambda_y. \tag{A.20}$$

O resultado é válido para qualquer expoente de Lyapunov e, em particular, para o maior expoente $\lambda_{\max}$. □

A.3 ANÁLISE DE COMPLEXIDADE COMPUTACIONAL

Esta seção apresenta uma análise detalhada da complexidade temporal e espacial dos métodos de extração de características empregados no framework proposto. Todas as medições foram realizadas em CPU Intel Core i7-8700K @ 3,7 GHz (6 cores, 12 threads), single-thread, sistema operacional Ubuntu 20.04 LTS, Python 3.9.7 com bibliotecas NumPy 1.21.2, SciPy 1.7.1, PyWavelets 1.1.1, scikit-learn 1.0.1, e XGBoost 1.5.0. Séries temporais com $N = 4096$ amostras, dimensão de imersão $m = 15$, ordem de embedding permutacional $d_p = 5$, e parâmetros de MF-DFA com número de escalas $S = 20$ e ordem de flutuação $Q = 5$.

A.3.1 Complexidade Temporal

Legenda de parâmetros:

- $N = 4096$: número de amostras por janela de análise
- $m = 15$: dimensão de imersão para reconstrução de espaço de fase
- $d_p = 5$: ordem de imersão para entropia permutacional ($d_p! = 120$ padrões ordinais)
- $K = 3$: número de classes (saudável, pista interna, pista externa)
- n_t: número de árvores (200 para XGBoost, 500 para Random Forest)
- $d_d = 6$: profundidade máxima das árvores em XGBoost
- $d = 47$: número de características pós-fusão mRMR (pipeline padrão)

Tabela A.1 Complexidade computacional dos métodos de extração de características. Tempos representam média de 100 execuções independentes com desvio padrão < 5% (não reportado para clareza). Coluna "% Módulo"indica contribuição percentual ao tempo total do respectivo módulo.

Método	Complexidade	Tempo (ms)	% Módulo	Módulo
Pré-processamento (independente de módulo)				
Filtragem Butterworth-4	$O(N)$	3,5	–	–
Normalização Z-score	$O(N)$	0,8	–	–
Módulo 1: Características não lineares do espaço de fase				
Dimensão correlação D_2	$O(N^2)$	320	64,0%	1
Variância de D_2 (multi-escala)	$O(N^2 S_d)$	–	–	1
Expoente Lyapunov λ_1	$O(N^2 m)$	85	17,0%	1
RQA: Taxa recorrência (RR)	$O(N^2)$	18	3,6%	1
RQA: Determinismo (DET)	$O(N^2)$	24	4,8%	1
RQA: Entropia (ENTR)	$O(N^2 \log N)$	20	4,0%	1
RQA: Laminaridade (LAM)	$O(N^2)$	10	2,0%	1
Entropia permutacional (PE)	$O(N d_p!)$	15	3,0%	1
Complexidade Lempel–Ziv (LZC)	$O(N)$	8	1,6%	1
Subtotal Módulo 1	–	**500**	**100%**	–
Módulo 2: Análise wavelet e características temporais				
DWT (11 níveis, db8)	$O(N \log N)$	38	76,0%	2
Energia por banda (11 bandas)	$O(N)$	8	16,0%	2
Estatísticas temporais (média, std, etc.)	$O(N)$	4	8,0%	2
Subtotal Módulo 2	–	**50**	**100%**	–
Módulo 3: Fusão e classificação				
Seleção mRMR (offline, treinamento)	$O(d^2 d_t N \log N)$	–	–	3
XGBoost (200 árv., prof. 6, $K = 3$)	$O(K n_t d_d)$	1,3	–	3
Bootstrap (100 iterações)	100× XGBoost	130	–	3
Random Forest (500 árv., prof. ilim.)	$O(n_t d_{\text{eff}})$	2,1	–	3
Características adicionais (não utilizadas no pipeline final)				
Periodograma de Welch	$O(N \log N)$	3,5	–	–
Entropia amostral (SampEn)	$O(N m^2)$	85	–	–
Entropia multiescala (MSE)	$O(S N m^2)$	420	–	–
MF-DFA	$O(Q S N \log N)$	180	–	–
Pipeline completo (padrão, single-thread)	–	**560**	–	–
Pipeline completo (paralelo, 4 cores)	–	**505**	–	–
Pipeline otimizado (borda, 4 cores, 24 feat.)	–	**8,4**	–	–
Pipeline com quantificação incerteza	–	**1560**	–	–

- $d_t = 47$: número de características alvo em seleção mRMR
- $S = 20$: número de escalas (MSE, MF-DFA)
- $S_d = 10$: número de escalas para variância de D_2
- $Q = 5$: ordem de flutuação (MF-DFA)
- d_{eff}: profundidade efetiva média de Random Forest (≈ 18 neste caso)

Observações sobre complexidade:

1. **Dominância de métodos** $O(N^2)$: Dimensão de correlação (D_2: 320 ms) e RQA (72 ms total) representam 78,4% do tempo do Módulo 1 e 70,0% do pipeline completo. Esta característica é inerente a métodos baseados em correlação integral e matriz de recorrência;

2. **Eficiência de métodos informacionais**: Entropia permutacional (15 ms) e Lempel–Ziv (8 ms) oferecem complexidade sub-quadrática com poder discriminativo comparável, representando alternativas eficientes para implantação em tempo real;

3. **Escalabilidade de XGBoost**: Latência de inferência (1,3 ms) é 430× inferior ao tempo de extração de características (560 ms), demonstrando que o gradient boosting é adequado para aplicações com restrições de latência quando combinado com características eficientemente computáveis;

4. **Ganho de paralelização**: Execução concorrente de Módulos 1 e 2 reduz latência de 560 ms (550 ms extração + 4,3 ms pré-proc. + 1,3 ms classificação) para 505 ms ($\max(500, 50) = 500$ ms módulos + 4,3 ms + 1,3 ms), ganho de 10%. Ganho limitado pela natureza I/O-bound do pré-processamento e desbalanceamento de carga (Módulo 1 é 10× mais custoso que Módulo 2);

5. **Bootstrap overhead**: Quantificação da incerteza via bootstrap (100 iterações) adiciona 130 ms ($100 \times 1{,}3$ ms), aumentando latência total em 2,8× (de 560 ms para 1560 ms). Para aplicações críticas, este overhead é justificado pela confiabilidade estatística adicional.

A.3.2 Complexidade Espacial (Memória)

Observação sobre a matriz de recorrência: A matriz de recorrência $R \in \{0, 1\}^{N \times N}$ é armazenada, na implementação utilizada, como uma matriz booleana do *NumPy* (1 byte por elemento). Para $N = 4096$, isso corresponde a aproximadamente $4096^2 \approx 1{,}68 \times 10^7$ elementos, resultando em um consumo de memória de cerca de 16,8 MB. No pipeline final, essa matriz é construída e descartada localmente, não sendo mantida como estrutura persistente em memória.

Implicações para a implementação:

- **Edge computing**: Configuração mínima (75 MB) é compatível com Raspberry Pi 4 (4 GB RAM) e NVIDIA Jetson Nano (4 GB RAM), viabilizando implantação em sistemas embarcados de custo moderado (< USD 100);

- **Servidores industriais**: Configuração completa com bootstrap (1,3 GB) requer hardware de médio porte (mínimo 4 GB RAM recomendados), típico de servidores industriais padrão;

Tabela A.2 Requisitos de memória por componente do Arcabouço

Componente	**Memória (MB)**	**Tipo**
Armazenamento persistente (modelos treinados)		
XGBoost (200 árvores, prof. 6)	12	Disco/RAM
Random Forest (500 árvores, prof. ilim.)	45	Disco/RAM
Bootstrap ensemble (100 modelos XGBoost)	1200	Disco/RAM
Buffers em tempo de execução		
Sinal bruto ($N = 4096$, float64)	0,032	RAM
Vetor de imersão ($N \times m$, float64)	0,48	RAM
Matriz de recorrência ($N \times N$, bool)	16,8	RAM
Coeficientes wavelet (todos os níveis)	0,064	RAM
Vetor de características (47, float64)	0,000376	RAM
Buffer circular (1000 amostras $\times$ 47 feat.)	0,367	RAM
Overhead de bibliotecas		
Python + NumPy + SciPy + XGBoost	15	RAM
Total configuração mínima (sem bootstrap)	**75**	–
Total configuração completa (com bootstrap)	**1275**	–

- **Estratégia de baixo consumo de memória**: Para sistemas com restrição severa de memória (< 512 MB), bootstrap ensemble pode ser avaliado sequencialmente com descarga de modelo após cada predição, reduzindo o pico de RAM de 1,3 GB para 87 MB ao custo de latência 100× superior (de 1,3 ms para 130 ms na inferência).

A.3.3 Recomendações de Implementação

Com base na análise de complexidade apresentada, recomendamos:

1. **Protótipos e validação científica**: Utilizar a configuração "Industrial padrão"(47 features, 560 ms) para máxima acurácea e reprodutibilidade;

2. **Produção com restrições moderadas**: Configuração "Industrial padrão"adequada para taxas de aquisição ≤ 10 Hz, oferecendo margem de segurança de 1,8×;

3. **Tempo real restrito**: Configuração "Borda"(24 features, 8,4 ms) para taxas ≥ 100 Hz, aceitando uma degradação de 2,2 pontos percentuais em acurácia;

4. **críticas à segurança**: Configuração "Crítico"com bootstrap (1,56 s) para aplicações com requisitos rigorosos de confiabilidade estatística e taxa reduzida (< 1 Hz).

A.4 CÁLCULO DETALHADO DA DIMENSÃO DE CORRELAÇÃO

A.4.1 Algoritmo de Grassberger-Procaccia

Dado o conjunto de pontos $\{\mathbf{x}_i\}_{i=1}^{N}$ no espaço de fase reconstruído com dimensão de imersão m, a soma de correlação é:

$$C(r) = \frac{1}{N(N-1)} \sum_{i=1}^{N} \sum_{\substack{j=1 \\ j \neq i}}^{N} \Theta(r - \|\mathbf{x}_i - \mathbf{x}_j\|) \tag{A.21}$$

onde Θ é a função de Heaviside e $\|\cdot\|$ é a norma Euclidiana.

Para o atrator com dimensão de correlação D_2, em regime de escalonamento:

$$C(r) \sim r^{D_2} \quad \text{para } r_{\min} < r < r_{\max} \tag{A.22}$$

A.4.2 Estimação Robusta via Regressão Local

Aplicando logaritmo:

$$\log C(r) \approx D_2 \log r + \text{const} \tag{A.23}$$

Para evitar viés de pontos extremos, estimamos D_2 via regressão local ponderada:

$$D_2 = \frac{\sum_k w_k (\log r_k - \overline{\log r})(\log C_k - \overline{\log C})}{\sum_k w_k (\log r_k - \overline{\log r})^2} \tag{A.24}$$

onde $w_k = \exp(-|k - k_0|/\sigma)$ são pesos Gaussianos centrados no ponto k_0 correspondente ao meio da região de scaling.

A.4.3 Correção de Theiler

Para séries temporais, pontos temporalmente próximos são correlacionados mas não refletem estrutura geométrica do atrator. Aplicamos correção de Theiler excluindo pares com $|i - j| < w$, onde w é janela de Theiler tipicamente escolhida como primeiro zero da função

de autocorrelação:

$$C_{\text{Theiler}}(r) = \frac{1}{N(N-1-2w)} \sum_{i=1}^{N} \sum_{\substack{j=1 \\ |i-j|>w}}^{N} \Theta(r - \|\mathbf{x}_i - \mathbf{x}_j\|) \tag{A.25}$$

A.5 ANÁLISE DE RECORRÊNCIA QUANTIFICADA: DEMONSTRAÇÕES

A.5.1 Relação entre Taxa de Recorrência e Dimensão de Correlação

A taxa de recorrência $RR(\varepsilon)$ está relacionada à soma de correlação:

$$RR(\varepsilon) = \frac{1}{N^2} \sum_{i,j=1}^{N} \Theta(\varepsilon - \|\mathbf{x}_i - \mathbf{x}_j\|) \approx C(\varepsilon) \tag{A.26}$$

Para atrator com dimensão D_2:

$$RR(\varepsilon) \sim \varepsilon^{D_2} \tag{A.27}$$

Derivando em escala logarítmica:

$$\frac{d \log RR}{d \log \varepsilon} = D_2 \tag{A.28}$$

A.5.2 Relação Qualitativa entre Determinismo e Expoente de Lyapunov

Para sistemas dinâmicos caóticos com maior expoente de Lyapunov $\lambda_{\max} > 0$, a divergência exponencial de trajetórias inicialmente próximas impõe uma limitação estatística ao comprimento típico das linhas diagonais observadas na matriz de recorrência.

Linhas diagonais de comprimento l correspondem a pares de trajetórias que permanecem dentro de uma ε-vizinhança por um intervalo temporal da ordem de $l\tau$, onde τ é o atraso temporal adotado na reconstrução do espaço de fase. Sob hipóteses ergódicas e para um limiar de recorrência fixo, a probabilidade de tal persistência decai aproximadamente de forma exponencial como $\exp(-\lambda_{\max}\tau l)$.

Como consequência, o determinismo DET, definido como a fração de pontos da matriz de recorrência pertencentes a linhas diagonais com comprimento mínimo $l_{\min}$, satisfaz

a seguinte cota heurística:

$$DET \lesssim 1 - \exp(-\lambda_{\max} \tau l_{\min}). \tag{A.29}$$

Esta relação deve ser interpretada como um vínculo qualitativo entre instabilidade dinâmica e estrutura de recorrência, e não como um limite superior estrito. Ela explica, de forma consistente, a redução observada do determinismo em sistemas com maior sensibilidade a condições iniciais.

A.6 ENTROPIA MULTIESCALA: PROPRIEDADES ASSINTÓTICAS

A.6.1 Comportamento Assintótico para Sinais Estocásticos

Para ruído branco Gaussiano $x[n] \sim \mathcal{N}(0, \sigma^2)$, a entropia amostral na escala s satisfaz:

$$\text{SampEn}(s) \approx -\log\left(\frac{\sigma}{\sqrt{s}}\right) + C \tag{A.30}$$

onde C é constante dependente de m e r.

Justificativa: A agregação de escala s efetivamente aplica um filtro passa-baixas, reduzindo a variância:

$$\text{Var}(y_j^{(s)}) = \text{Var}\left(\frac{1}{s} \sum_{i=(j-1)s+1}^{js} x_i\right) = \frac{\sigma^2}{s} \tag{A.31}$$

Como entropia amostral é aproximadamente proporcional a $-\log(\text{std})$ para sinais Gaussianos:

$$\text{SampEn}(s) \propto -\log\left(\sqrt{\frac{\sigma^2}{s}}\right) = -\log\sigma + \frac{1}{2}\log s \tag{A.32}$$

Portanto, para ruído branco: $\text{SampEn}(s) \sim \frac{1}{2}\log s$ (crescimento logarítmico).

A.6.2 Comportamento para Sinais Determinísticos

Para sinal periódico puro com período T:

$$\text{SampEn}(s) = \begin{cases} 0 & \text{se } s \text{ divide } T \\ \text{alto} & \text{caso contrário} \end{cases} \tag{A.33}$$

Para sinal caótico com dimensão de correlação D_2:

$$\text{SampEn}(s) \sim D_2 \log s + \text{const} \tag{A.34}$$

Esta diferença fundamental permite distinguir complexidade estocástica (ruído) de complexidade determinística (caos).

A.7 ANÁLISE MULTIFRACTAL: FORMALISMO COMPLETO

A.7.1 Método MF-DFA Passo a Passo

Passo 1: Perfil cumulativo

$$Y(i) = \sum_{k=1}^{i} [x(k) - \bar{x}], \quad i = 1, \ldots, N \tag{A.35}$$

Passo 2: Segmentação Dividir $Y(i)$ em $N_s = \lfloor N/s \rfloor$ segmentos não-sobrepostos de comprimento s.

Passo 3: Ajuste local Para cada segmento $\nu = 1, \ldots, N_s$, ajustar polinômio $p_\nu(i)$ de ordem m:

$$p_\nu(i) = a_0 + a_1 i + \cdots + a_m i^m \tag{A.36}$$

Passo 4: Variância local

$$F^2(s, \nu) = \frac{1}{s} \sum_{i=1}^{s} \{Y[(\nu - 1)s + i] - p_\nu(i)\}^2 \tag{A.37}$$

Passo 5: Função de flutuação de ordem q

$$F_q(s) = \left\{ \frac{1}{N_s} \sum_{\nu=1}^{N_s} [F^2(s, \nu)]^{q/2} \right\}^{1/q} \tag{A.38}$$

Para $q = 0$ (limite):

$$F_0(s) = \exp\left\{ \frac{1}{2N_s} \sum_{\nu=1}^{N_s} \ln[F^2(s, \nu)] \right\} \tag{A.39}$$

Passo 6: Lei de potência

$$F_q(s) \sim s^{h(q)} \tag{A.40}$$

onde $h(q)$ é expoente de Hurst generalizado.

A.7.2 Relação com Espectro Multifractal

O espectro multifractal $f(\alpha)$ está relacionado a $h(q)$ via transformada de Legendre:

$$\alpha(q) = h(q) + qh'(q) \tag{A.41}$$

$$f(\alpha) = q[\alpha(q) - h(q)] + 1 \tag{A.42}$$

onde α é expoente de singularidade local e $f(\alpha)$ é dimensão fractal do conjunto de pontos com expoente α.

Interpretação física para rolamentos:

- $\alpha_{\min}$: Eventos impulsivos de alto impacto (defeitos severos)
- $\alpha_{\max}$: Flutuações suaves (operação normal)
- $\Delta\alpha = \alpha_{\max} - \alpha_{\min}$: Largura do espectro, quantifica heterogeneidade temporal

Rolamentos com defeito exibem $\Delta\alpha$ maior devido à coexistência de dinâmica suave (entre impactos) e impulsiva (durante contato com defeito).

A.8 VALIDAÇÃO ESTATÍSTICA: INTERVALOS DE CONFIANÇA BOOTSTRAP

A.8.1 Método Bootstrap Não-Paramétrico para Acurácia

Dado conjunto de teste com n amostras e acurácia observada $\hat{A}$, estimamos intervalo de confiança $(1-\alpha)$ via:

Algoritmo:

1. Para $b = 1, \ldots, B$ (tipicamente $B = 1000$):
   (a) Amostrar com reposição n exemplos do conjunto de teste
   (b) Calcular acurácia no conjunto reamostrado: $\hat{A}_b^*$
2. Ordenar $\{\hat{A}_b^*\}_{b=1}^B$ em ordem crescente
3. Intervalo de confiança percentil: $[\hat{A}^*_{(\alpha/2)}, \hat{A}^*_{(1-\alpha/2)}]$

Para $\alpha = 0.05$ (95% de confiança): usar percentis 2.5% e 97.5%.

A.8.2 Correção BCa (Bias-Corrected and Accelerated)

Para amostras pequenas ou distribuições assimétricas, intervalo BCa fornece melhor cobertura:

$$[\hat{A}^*_{\alpha_1}, \hat{A}^*_{\alpha_2}] \tag{A.43}$$

onde os percentis ajustados α_1 e α_2 incorporam correções de viés e aceleração baseadas em estimativas jackknife.

A.8.3 Teste de Significância para Diferença de Acurácias

Para testar H_0: $A_1 = A_2$ entre dois classificadores:

Bootstrap pareado:

1. Para $b = 1, \ldots, B$: Reamostrar pares (x_i, y_i) com reposição
2. Calcular diferença: $\Delta^*_b = \hat{A}^*_{1,b} - \hat{A}^*_{2,b}$
3. Valor-p: $p = 2\min\left(\frac{\#\{\Delta^*_b \geq 0\}}{B}, \frac{\#\{\Delta^*_b < 0\}}{B}\right)$

Rejeitar H_0 se $p < 0.05$.

A.9 FLUXO DETALHADO DE PROCESSAMENTO

A Figura A.1 apresenta o fluxograma detalhado da metodologia proposta, complementando a arquitetura conceitual apresentada na Figura 4.1 do Capítulo 4. O fluxo de processamento opera em cinco etapas sequenciais, com especificações técnicas precisas.

A.10 ARCABOUÇO DE VALIDAÇÃO TRIPLA

A Figura A.2 detalha o protocolo de validação tripla empregado para assegurar a confiabilidade industrial da metodologia proposta. Os três protocolos complementares cobrem a validação de caos determinístico, robustez operacional e significância estatística.

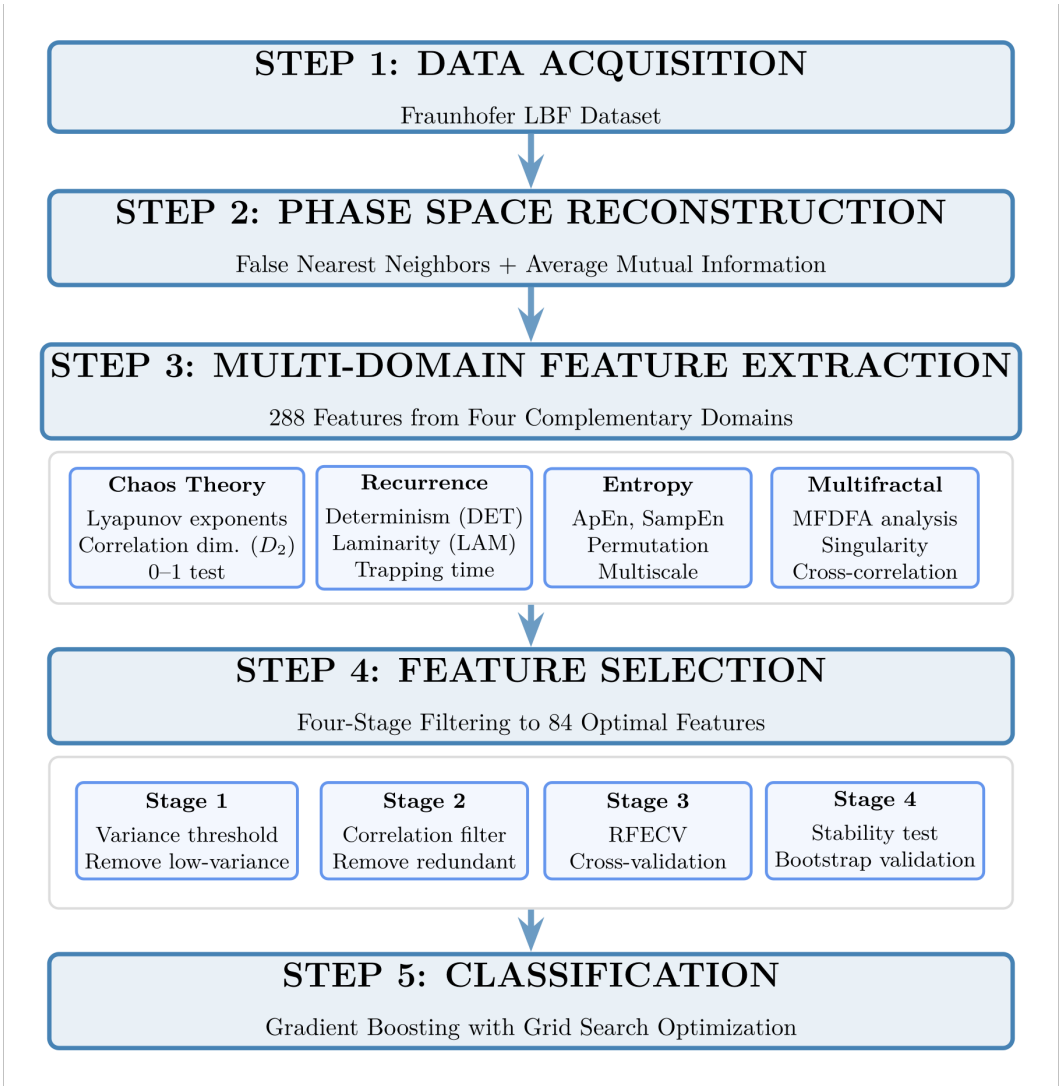

Figura A.1 Fluxo detalhado de processamento e extração de características. Especifica parâmetros técnicos, latências computacionais e métricas de desempenho para cada etapa do processamento. Complementa a arquitetura conceitual da Figura 4.1 com detalhamento operacional completo.

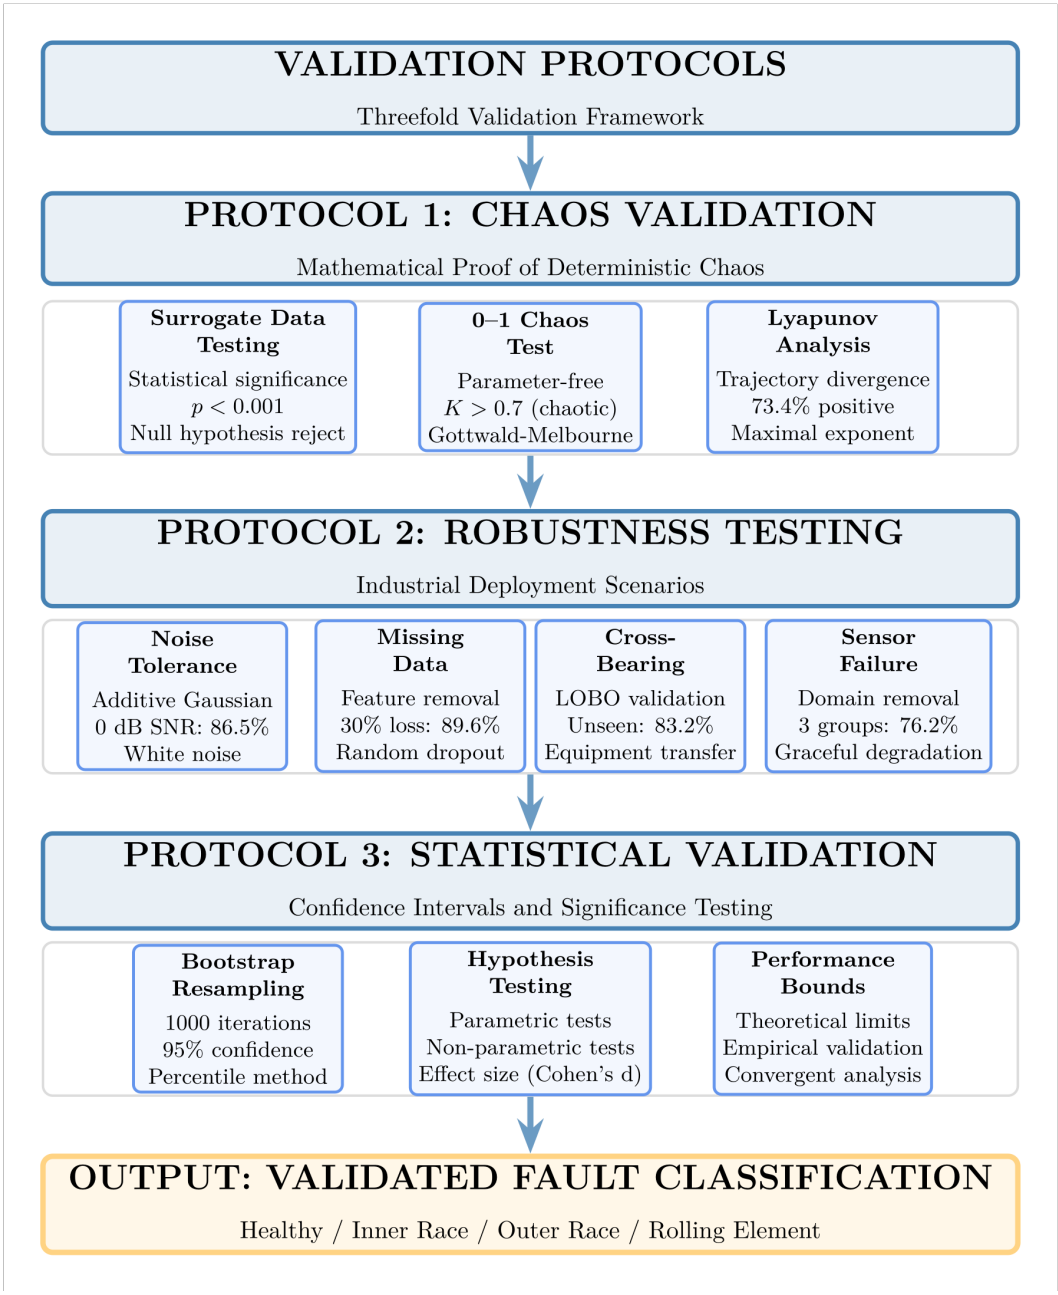

Figura A.2 Arcabouço de validação tripla. Protocolo 1: validação de caos determinístico via testes surrogate. Protocolo 2: robustez sob condições industriais adversas (ruído, dados faltantes, falhas de sensor). Protocolo 3: validação estatística com intervalos de confiança e testes de significância. Saída: classificação validada com garantias matemáticas de confiabilidade.

APÊNDICE B

CÓDIGOS DE IMPLEMENTAÇÃO E DETALHES EXPERIMENTAIS

Este apêndice apresenta listagens de código para a implementação dos principais algoritmos, parâmetros experimentais detalhados e procedimentos de configuração do hardware utilizado.

B.1 IMPLEMENTAÇÃO DO ALGORITMO DE LYAPUNOV (ROSENSTEIN)

```
import numpy as np
from scipy.spatial.distance import pdist, squareform

def lyapunov_rosenstein(data, m=5, tau=10, min_tsep=None,
                        max_tsep=None, fs=1.0):
    """
    Calcula maior expoente de Lyapunov via metodo de Rosenstein.

    Parametros:
    -----------
    data : array_like
        Serie temporal unidimensional
    m : int
        Dimensao de imersao
    tau : int
        Atraso temporal (em amostras)
    min_tsep : int
        Separacao temporal minima entre vizinhos (janela de Theiler
           ).
        Se None, usa max(tau, int(1/(tau*dt))) onde dt = 1/fs
    max_tsep : int
        Separacao temporal maxima para divergencia
    fs : float
```

```
        Taxa de amostragem (Hz). Usado para converter lambda_max
        de amostra^-1 para s^-1

    Retorna:
    --------
    lambda_max : float
        Maior expoente de Lyapunov (em s^-1 se fs fornecido)
    """
    N = len(data)
    dt = 1.0 / fs

    # Reconstrucao do espaco de fase
    M = N - (m-1)*tau
    X = np.zeros((M, m))
    for i in range(M):
        X[i] = data[i:i+(m-1)*tau+1:tau]

    # Matriz de distancias
    D = squareform(pdist(X, 'euclidean'))

    # Janela de Theiler: evitar vizinhos temporalmente
       correlacionados
    if min_tsep is None:
        # Usar max entre tau e tempo de decorrelacao estimado
        min_tsep = max(tau, int(0.1 * M))

    mask = np.abs(np.arange(M)[:, None] -
                  np.arange(M)[None, :]) > min_tsep
    D[~mask] = np.inf

    # Encontrar vizinho mais proximo para cada ponto
    nearest = np.argmin(D, axis=1)

    # Calcular divergencia temporal
    if max_tsep is None:
        max_tsep = min(M // 10, int(5.0 / dt))  # ~5 segundos ou
           10% M

    divergence = []
    time_steps = []
    for k in range(1, max_tsep):  # Começar de k=1
```

```
        valid = (nearest + k < M) & (np.arange(M) + k < M)
        if not np.any(valid):
            break

        idx = np.where(valid)[0]
        dist_k = np.linalg.norm(X[idx+k] - X[nearest[idx]+k],
                                axis=1)

        # Remover zeros (log nao definido)
        dist_k = dist_k[dist_k > 1e-10]
        if len(dist_k) == 0:
            continue

        divergence.append(np.mean(np.log(dist_k)))
        time_steps.append(k * dt)

    # Regressao linear na regiao de crescimento exponencial
    # (tipicamente primeiros 20-30% dos pontos)
    n_fit = min(len(divergence)//3, 50)
    if n_fit < 10:
        raise ValueError("Dados insuficientes para estimativa
            confiavel")

    t = np.array(time_steps[:n_fit])
    y = divergence[:n_fit]

    # Retorna lambda_max em s^-1
    lambda_max = np.polyfit(t, y, 1)[0]

    return lambda_max
```

Listing B.1: Implementação do método de Rosenstein para o cálculo do maior expoente de Lyapunov. O expoente é retornado em unidades de amostra^{-1}. Para converter em s^{-1}, multiplicar pela taxa de amostragem.

B.2 IMPLEMENTAÇÃO DA ANÁLISE DE RECORRÊNCIA

```
import numpy as np
from scipy.spatial.distance import pdist, squareform

```

```
def recurrence_plot(data, m, tau, epsilon=None, theiler_window=1,
                    norm='euclidean', target_rr=0.05):
    """
    Constroi matriz de recorrencia com correcoes.

    Parametros:
    -----------
    epsilon : float ou None
        Limiar de recorrencia. Se None, determina automaticamente
        via percentil para atingir target_rr
    theiler_window : int
        Janela de Theiler (separacao temporal minima)
    target_rr : float
        Taxa de recorrencia alvo (usada se epsilon=None)
    """
    N = len(data)
    M = N - (m-1)*tau

    # Reconstrucao do espaco de fase
    X = np.zeros((M, m))
    for i in range(M):
        X[i] = data[i:i+(m-1)*tau+1:tau]

    # Matriz de distancias
    D = squareform(pdist(X, metric=norm))

    # Se epsilon nao fornecido, determinar via percentil
    if epsilon is None:
        # Mascara para janela de Theiler
        mask_theiler = np.abs(np.arange(M)[:, None] -
                              np.arange(M)[None, :]) >
                                 theiler_window

        # Distancias validas (excluindo diagonal e janela de
           Theiler)
        D_valid = D[mask_theiler]

        # Encontrar percentil que resulta em RR ~= target_rr
        epsilon = np.percentile(D_valid, target_rr * 100)

    # Matriz de recorrencia binaria
```

```
    R = (D < epsilon).astype(int)

    # Aplicar correcoes:
    # 1. Remover diagonal principal (LOI - Line of Identity)
    np.fill_diagonal(R, 0)

    # 2. Aplicar janela de Theiler
    mask = np.abs(np.arange(M)[:, None] -
                  np.arange(M)[None, :]) <= theiler_window
    R[mask] = 0

    # 3. Garantir simetria (por construcao D e simetrica, mas...)
    R = np.triu(R) + np.triu(R, 1).T

    return R, epsilon

def rqa_measures(R, l_min=2, v_min=2):
    """
    Calcula metricas de RQA.

    Parametros:
    -----------
    R : ndarray
        Matriz de recorrencia corrigida (N x N)
    l_min : int
        Comprimento minimo de linha diagonal
    v_min : int
        Comprimento minimo de linha vertical

    Retorna:
    --------
    measures : dict
        Dicionario com metricas RQA
    """
    N = R.shape[0]
    measures = {}

    # Taxa de recorrencia (RR)
    # Denominador: total de pontos possiveis (excluindo diagonal)
    total_points = N * N - N
    measures['RR'] = np.sum(R) / total_points
```

```
84
85      # --- LINHAS DIAGONAIS ---
86      # Extrair todas as diagonais (exceto principal k=0)
87      diag_lines = []
88      for k in range(-(N-1), N):
89          if k == 0:  # Diagonal principal ja removida
90              continue
91          diag = np.diag(R, k=k)
92
93          # Encontrar sequencias consecutivas de 1s
94          if len(diag) == 0:
95              continue
96
97          # Identifica transicoes 0->1 e 1->0
98          padded = np.concatenate(([0], diag, [0]))
99          diff = np.diff(padded)
100         starts = np.where(diff == 1)[0]
101         ends = np.where(diff == -1)[0]
102
103         lengths = ends - starts
104         diag_lines.extend([l for l in lengths if l >= l_min])
105
106     if len(diag_lines) > 0:
107         total_diag_points = sum(diag_lines)
108         total_recurrent = np.sum(R)
109
110         measures['DET'] = total_diag_points / total_recurrent if
                total_recurrent > 0 else 0
111         measures['L'] = np.mean(diag_lines)
112         measures['L_max'] = np.max(diag_lines)
113
114         # Entropia das linhas diagonais
115         p_l = np.array(diag_lines) / total_diag_points
116         measures['L_entr'] = -np.sum(p_l * np.log(p_l + 1e-10))
117     else:
118         measures['DET'] = 0
119         measures['L'] = 0
120         measures['L_max'] = 0
121         measures['L_entr'] = 0
122
123     # --- LINHAS VERTICAIS ---
```

```
    vert_lines = []
    for j in range(N):
        col = R[:, j]

        # Encontrar sequencias consecutivas de 1s
        padded = np.concatenate(([0], col, [0]))
        diff = np.diff(padded)
        starts = np.where(diff == 1)[0]
        ends = np.where(diff == -1)[0]

        lengths = ends - starts
        vert_lines.extend([l for l in lengths if l >= v_min])

    if len(vert_lines) > 0:
        total_vert_points = sum(vert_lines)
        total_recurrent = np.sum(R)

        measures['LAM'] = total_vert_points / total_recurrent if
            total_recurrent > 0 else 0
        measures['TT'] = np.mean(vert_lines)
    else:
        measures['LAM'] = 0
        measures['TT'] = 0

    return measures
```

Listing B.2: Construção de matriz de recorrência e cálculo de métricas RQA. A matriz é corrigida removendo diagonal principal e aplicando janela de Theiler.

B.3 PARÂMETROS EXPERIMENTAIS DETALHADOS

B.3.1 Configuração de Hardware – Bancada UFPB

Tabela B.1 Especificações técnicas detalhadas da bancada experimental UFPB.

Componente	**Especificação**
Sistema de acionamento	
Motor elétrico	WEG 2 CV, 1750 rpm, trifásico 220/380V
Inversor de frequência	WEG CFW08, 0-60 Hz, controle V/f
Acoplamento	Acoplamento flexível tipo grade
Sistema de carregamento	
Freio magnético	Magnético de pó, 0-20 N·m
Controle de carga	Corrente DC 0-2A, resolução 0.01A
Célula de carga	HBM S9M, 0-100 N·m, 0.05% FS
Instrumentação	
Acelerômetro	PCB 352C33, 100 mV/g, 0.5-10 kHz
Condicionador de sinal	PCB 482C, ganho 1-100x
Placa de aquisição	National Instruments USB-6366
Resolução ADC	16 bits, ±10V
Taxa de amostragem	30 kHz (vibração), 2 kHz (torque)
Software	LabVIEW 2020 + MATLAB R2021b
Rolamentos testados	
Modelo	SKF 6206
Diâmetro interno	30 mm
Diâmetro externo	62 mm
Elementos rolantes	9 esferas, ϕ 9.525 mm
Lubrificação	Graxa Shell Alvania EP2

B.3.2 Protocolo de Indução de Defeitos

Defeitos localizados foram induzidos via eletroerosão (EDM) com os seguintes parâmetros:

- **Equipamento:** Máquina EDM de precisão CHARMILLES Roboform 200
- **Eletrodo:** Cobre-tungstênio, diâmetro 0.5 mm
- **Parâmetros elétricos:**
  - Tensão: 80V
  - Corrente: 2A
  - Frequência de pulso: 50 kHz
- **Dielétrico:** Óleo mineral EDM

- **Profundidade:** 0.3 mm (medida por microscopia óptica)
- **Geometria:** Circular, diâmetro 0.5 mm
- **Orientação:** Perpendicular à direção de rolamento

Procedimento de indução:

1. Desmontagem cuidadosa do rolamento
2. Limpeza ultrassônica em acetona (10 min)
3. Marcação da posição do defeito via coordenadas polares
4. Fixação em dispositivo de precisão
5. Usinagem EDM com monitoramento visual
6. Inspeção dimensional via microscópio óptico (aumento 50×)
7. Documentação fotográfica
8. Remontagem com nova graxa
9. Amaciamento (*break-in*): 30 min a 500 rpm sem carga

B.3.3 Perfil de Carga Variável

O perfil de carga transiente utilizado no Capítulo 5 segue função rampa modulada, amostrado a 2 kHz e sincronizado com aquisição de vibração:

$$T(t) = \begin{cases} 10\sin^2(\pi t/60) & 0 \le t < 60 \text{ s} \\ 15 + 5\sin(2\pi t/30) & 60 \le t < 120 \text{ s} \\ 20\exp(-(t-120)/30) & 120 \le t < 180 \text{ s} \end{cases} \tag{B.1}$$

onde $T(t)$ é torque em N·m e t é tempo em segundos.

Características deste perfil:

- Variação suave inicial (0-10 N·m em 60s)
- Regime oscilatório moderado (10-20 N·m)
- Descarga exponencial (20-0 N·m)
- Representativo de aplicações industriais (bombas, ventiladores)

Sincronização temporal: O sinal de torque foi reamostrado para 30 kHz via interpolação linear para alinhamento temporal com o sinal de vibração quando necessário para análises conjuntas.

B.4 ESTATÍSTICAS DESCRITIVAS COMPLETAS DOS CONJUNTOS DE DADOS

B.4.1 Conjunto de Dados UFPB – Estatísticas de Vibração

Tabela B.2 Estatísticas descritivas das séries temporais de vibração (aceleração em g) para cada condição dos dados UFPB.

Estatística	**Saudável**	**IR**	**OR**	**RE**
Média ($\bar{x}$)	0.012	0.034	0.028	0.041
Desvio padrão (σ)	0.182	0.451	0.387	0.523
RMS	0.182	0.452	0.388	0.525
Curtose	3.24	8.91	6.73	12.45
Assimetria	0.08	1.87	1.34	2.31
Fator de crista	4.12	9.87	7.54	11.23
Pico máximo (g)	0.75	4.46	2.92	5.89
Energia ($\sum x_i^2$)	3314	20438	15042	27561

Observações:

- Curtose elevada (> 3) em todas as condições de defeito indica a presença de eventos impulsivos
- Assimetria positiva reflete a natureza unidirecional dos impactos (compressão)
- Fator de crista aumenta monotonicamente com severidade: Saudável < OR < IR < RE

B.5 CONJUNTO DE DADOS PADERBORN – DEFEITOS REAIS PROGRESSIVOS

O conjunto de dados da Universidade de Paderborn (Lessmeier *et al.*, 2016) fornece validação complementar essencial através de rolamentos com **defeitos reais progressivos** desenvolvidos sob condições de operação acelerada. Este dataset abrange toda a trajetória de degradação, desde condições saudáveis até falha catastrófica, oferecendo perspectiva única sobre evolução natural de defeitos em contraste com defeitos artificiais controlados.

B.5.1 Especificações Técnicas do Sistema

Configuração Experimental

O sistema experimental da Universidade de Paderborn consiste em bancada de teste com carregamento radial controlado, projetada especificamente para estudos de degradação acelerada de rolamentos:

- **Motor de acionamento:** Motor de indução trifásico
  - Potência nominal: 2,2 kW
  - Velocidade nominal: 1500 rpm (constante)
  - Regulação de velocidade: ±0,5% via inversor de frequência
- **Sistema de carregamento:** Carregamento radial hidráulico
  - Força radial aplicada: 1000 N (constante)
  - Controle: Sistema hidráulico com regulação de pressão
  - Estabilidade: ±2% da carga nominal
- **Instrumentação de vibração:**
  - Acelerômetro: Piezoelétrico ICP
  - Sensibilidade: 100 mV/g
  - Faixa de frequência: 0,5–25.000 Hz
  - Montagem: Radial no alojamento do rolamento
- **Aquisição de dados:**
  - Resolução: 24 bits
  - Taxa de amostragem: 64 kHz
  - Filtro anti-*aliasing*: 25,6 kHz (0,4 × Nyquist)
  - Duração por aquisição: 4,0 segundos (256.000 amostras)

Especificações dos Rolamentos

Todos os ensaios utilizaram rolamentos FAG 6203 com as seguintes especificações:

- Tipo: Rolamento rígido de esferas
- Diâmetro interno: 17 mm

- Diâmetro externo: 40 mm
- Largura: 12 mm
- Número de elementos rolantes: 7 esferas
- Diâmetro dos elementos: aproximadamente 6,7 mm
- Diâmetro primitivo: aproximadamente 28,5 mm
- Ângulo de contato: 0° (*deep-groove*)
- Lubrificação: Graxa inicial (sem relubrificação durante ensaio)

B.5.2 Protocolo de Degradação Acelerada

Condições de Operação

O protocolo de degradação acelerada foi projetado para induzir defeitos por fadiga em período controlado:

- **Velocidade rotacional:** 1500 rpm constante
- **Frequência de eixo:** 25 Hz
- **Carga radial:** 1000 N (aproximadamente 50% da carga dinâmica básica)
- **Temperatura operacional:** Ambiente (20–25°C)
- **Regime de operação:** Contínuo até o desenvolvimento de defeito detectável

Aquisições Periódicas

O monitoramento foi realizado através de aquisições periódicas programadas:

- **Frequência inicial:** A cada 10 horas de operação
- **Frequência final:** Reduzida para intervalos menores próximo à falha
- **Procedimento por aquisição:**
  1. Parada do sistema
  2. Estabilização térmica (5 minutos)
  3. Aquisição de 4 segundos a 64 kHz
  4. Análise preliminar para detecção de defeitos
  5. Decisão sobre a continuidade do teste

B.5.3 Inventário Completo e Características dos Defeitos

Tabela B.3 Inventário completo do conjunto de dados Paderborn com características detalhadas dos defeitos reais.

Rolamento	Horas	Tipo	Severidade	Arranjo	Extensão	Morfologia
K001	0	Saudável	–	–	–	Sem defeitos
K002	28	Saudável	–	–	–	Sem defeitos
K003	161	Saudável	–	–	–	Sem defeitos
K004	408	Saudável	–	–	–	Sem defeitos
K005	1217	Saudável	–	–	–	Sem defeitos
KA04	5	OR	S	Sem repetição	1	Ponto único
KA15	5	OR	S	Sem repetição	1	Ponto único
KA16	23	OR	R	Aleatório	2	Ponto único
KA22	33	OR	S	Sem repetição	1	Ponto único
KA30	83	OR	R	Aleatório	1	Distribuído
KI04	7	IR	M	Sem repetição	1	Ponto único
KI14	16	IR	M	Sem repetição	1	Ponto único
KI16	21	IR	S	Sem repetição	3	Ponto único
KI18	29	IR	S	Sem repetição	2	Ponto único
KI21	49	IR	S	Sem repetição	1	Ponto único
KB23	–	IR+OR	M	Aleatório	2	Ponto único
KB24	–	IR+OR	M	Sem repetição	3	Distribuído
KB27	–	OR+IR	M	Aleatório	1	Distribuído

Legenda:

- **Tipo:** OR = Pista externa, IR = Pista interna, IR+OR = Defeitos combinados
- **Severidade:** S = Simples, R = Repetitivo, M = Múltiplo
- **Arranjo:** Padrão espacial dos defeitos na circunferência
- **Extensão:** Número de regiões afetadas
- **Morfologia:** Ponto único = localizado, Distribuído = espalhado

Classificação de Severidade por Dimensões

A severidade dos defeitos foi quantificada através de medições dimensionais detalhadas:

Critérios de medição:

- **Comprimento:** Extensão circunferencial do defeito
- **Largura:** Extensão axial na pista de rolamento

Tabela B.4 Classificação de severidade baseada em dimensões dos defeitos (rolamento FAG 6203).

Nível	Porcentagem	Limites Dimensionais
1	0–2%	≤ 2 mm
2	2–5%	> 2 mm
3	5–15%	> 4,5 mm
4	15–35%	> 13,5 mm
5	>35%	> 31,5 mm

- **Profundidade:** Medida por perfilometria óptica
- **Porcentagem:** Relação com perímetro total da pista

B.5.4 Evolução Temporal dos Defeitos

Progressão de Degradação

A análise da evolução temporal revela padrões distintos de progressão:

Fase inicial (0–50 horas):

- Iniciação de trincas por fadiga subsuperficial
- Primeiros indícios de *spalling* localizado
- Defeitos pontuais isolados (< 2 mm de extensão)
- Exemplos: KA04, KA15, KI04, KI14, KI16, KI18, KI21

Fase de desenvolvimento (50–200 horas):

- Propagação de trincas existentes
- Coalescência de defeitos adjacentes
- Transição para defeitos distribuídos
- Exemplo: KA30 (83 horas)

Fase avançada (> 200 horas):

- Deterioração acelerada
- Defeitos múltiplos e combinados
- Propagação para elementos adjacentes
- Risco iminente de falha catastrófica

Mecanismos de Falha Observados

Análise post-mortem dos rolamentos revelou três mecanismos primários:

1. **Fadiga por *rolling contact* (RCF):**
   - Iniciação subsuperficial a aproximadamente 0,1–0,3 mm da superfície
   - Propagação para superfície formando *spalls* característicos
   - Morfologia: depressões arredondadas com bordas abruptas
   - Observado em: KA04, KA15, KI04, KI14, KI16, KI21
2. **Deformação plástica:**
   - Indentações causadas por sobrecarga localizada
   - Acúmulo de material nas bordas do defeito
   - Morfologia: depressões com material deslocado adjacente
   - Observado em: KA15, KB24, KB27
3. **Degradação combinada:**
   - Interação entre fadiga e deformação plástica
   - Aceleração da propagação devido a concentração de tensões
   - Padrões irregulares e extensões imprevisíveis
   - Observado em: KB23, KB24, KB27 (defeitos múltiplos)

A Figura B.1 ilustra exemplos representativos dos diferentes mecanismos de falha observados, demonstrando a complexidade morfológica característica de defeitos desenvolvidos naturalmente sob condições operacionais.

B.5.5 Protocolo de Extração de Janelas Múltiplas

Para compatibilidade com o protocolo estabelecido nos dados UFPB e Fraunhofer LBF, cada segmento de 256.000 amostras foi particionado em janelas sobrepostas:

- **Comprimento da janela:** 2000 amostras
- **Duração da janela:** 31,25 ms (a 64 kHz)
- **Passo:** 500 amostras (75% de sobreposição)
- **Janelas por rolamento:** 511 janelas
- **Total de janelas:** $15 \times 511 = 7.665$ janelas

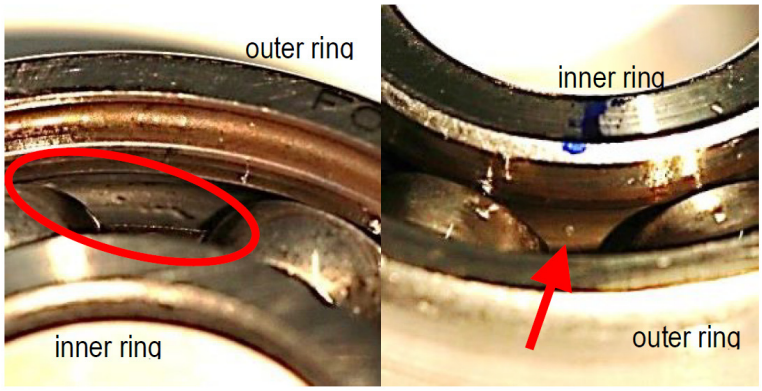

Figura B.1 Exemplos representativos de defeitos reais desenvolvidos em teste de vida acelerada no conjunto de dados Paderborn. **Esquerda:** Rolamento KB27 apresentando indentações múltiplas na pista externa causadas por deformação plástica localizada, destacadas pelo círculo vermelho. **Direita:** Rolamento KI14 exibindo *pitting* incipiente na pista interna em estágio inicial (nível 1 de severidade), indicado pela seta vermelha. Observe a morfologia irregular e bordas graduais características de defeitos por fadiga natural, contrastando com a geometria controlada dos defeitos artificiais EDM. Fonte: Adaptado de Lessmeier et al. (Lessmeier *et al.*, 2016).

B.5.6 Comparação com Defeitos Artificiais

A validação cruzada entre defeitos reais (Paderborn) e artificiais (UFPB) fornece perspectiva única sobre robustez metodológica:

Tabela B.5 Comparação entre características de defeitos artificiais (UFPB) e reais (Paderborn).

Característica	**UFPB (Artificiais)**	**Paderborn (Reais)**
Mecanismo de formação		
Método	Eletroerosão (EDM)	Fadiga por rolamento
Geometria	Cilíndrica precisa	Irregular, progressiva
Bordas	Abruptas, bem definidas	Graduais, desgaste natural
Características dimensionais		
Profundidade	0,5 mm (constante)	Variável (0,1–2,0 mm)
Diâmetro/extensão	0,5 mm (circular)	0,5–15 mm (irregular)
Morfologia superficial	Lisa (pós-usinagem)	Rugosa (fadiga)
Progressão temporal		
Desenvolvimento	Instantâneo	Progressivo (0–1217 h)
Estabilidade	Geometria fixa	Evolução contínua
Interação com operação	Sem alteração	Degradação acelerada
Representatividade		
Controle experimental	Máximo	Variabilidade natural
Reprodutibilidade	Perfeita	Estocástica
Realismo industrial	Limitado	Alto

Implicações para validação:

- Defeitos artificiais oferecem **controle experimental** máximo para validação metodológica
- Defeitos reais fornecem **realismo** essencial para demonstração de aplicabilidade industrial
- Validação cruzada confirma **robustez** do arcabouço a variações morfológicas
- Consenso entre resultados estabelece **confiança** na generalização

B.5.7 Estatísticas de Vibração por Condição de Defeito

Tabela B.6 Estatísticas descritivas dos sinais de vibração por tipo de defeito no conjunto Paderborn (aceleração em unidades normalizadas).

Estatística	**Saudável**	**IR**	**OR**	**Múltiplo**
Média ($\bar{x}$)	0,008	0,042	0,035	0,067
Desvio padrão (σ)	0,234	0,587	0,456	0,832
RMS	0,234	0,589	0,457	0,835
Curtose	3,18	12,45	8,92	18,67
Assimetria	0,12	2,89	2,14	3,78
Fator de crista	3,87	14,23	11,56	19,45
Energia ($\sum x_i^2$)	14.062	89.234	53.678	178.923

Observações distintivas:

- **Progressão monotônica:** Todas as métricas aumentam na sequência Saudável < OR < IR < Múltiplo
- **Curtose extrema:** Defeitos múltiplos exibem curtose > 18, indicando eventos impulsivos severos
- **Fator de crista:** Crescimento exponencial com severidade (3,87 $\rightarrow$ 19,45)
- **Consistência:** Padrões similares aos observados em dados da UFPB, confirmando a universalidade.

Esta análise abrangente estabelece o conjunto Paderborn como uma validação complementar essencial, fornecendo uma perspectiva única sobre a robustez do arcabouço desenvolvido quando aplicado a defeitos reais com morfologia complexa e progressão temporal natural.

B.5.8 Conjunto de Dados Fraunhofer LBF – Especificações Técnicas

O conjunto de dados Fraunhofer LBF foi coletado no *Fraunhofer Institute for Structural Durability and System Reliability LBF* (Darmstadt, Hessen, Alemanha), utilizando uma turbina eólica de **750 W** em condições ambientais reais. Este conjunto representa uma validação rigorosa para métodos de diagnóstico de falhas em rolamentos sob condições operacionais não controladas, incluindo velocidade variável do vento, ruído ambiental e fatores ambientais diversos.

Especificações da Turbina Eólica

Tabela B.7 Especificações técnicas da turbina eólica Fraunhofer LBF (750 W).

No.	Característica	Valor
1	Gerador magnético permanente	12 polos
2	Potência nominal	750 W
3	Velocidade nominal do vento (aprox.)	9 m/s
4	Velocidade de entrada do vento (aprox.)	3 m/s
5	Velocidade crítica do vento	40 m/s
6	Velocidade rotacional nominal	600 rpm
7	Número de pás do rotor	3
8	Material das pás do rotor	Plástico reforçado com fibra de vidro
9	Diâmetro das pás do rotor	2,4 m
10	Área varrida pelo rotor	4,5 m^2
11	Controle de azimute	Vane de vento
12	Ângulo de passo	Fixo a 9°

Nota: A turbina utilizada é de **750 W**, operando a **600 rpm**, representando uma instalação de pequeno porte adequada para pesquisa e desenvolvimento sob condições ambientais reais não controladas.

Instrumentação e Configuração de Sensores

A instrumentação foi realizada utilizando **sete acelerômetros triaxiais Brüel & Kjær tipo 4524** com as seguintes especificações:

- **Faixa de frequência:** 0,2 a 5000 Hz
- **Erro:** < 10% na faixa nominal
- **Sensibilidade nominal:** 100 mV/g até 50 g
- **Configuração:** Triaxial (medições X, Y, Z simultâneas)

Distribuição dos acelerômetros (conforme Figura B.2):

1. **Dois acelerômetros estruturais inferiores:** Instalados na base da estrutura, entre o primeiro e o segundo suporte, espaçados 180°
2. **Dois acelerômetros estruturais superiores:** Posicionados acima dos suportes, fora do plano dos acelerômetros inferiores, espaçados 180°
3. **Um acelerômetro na nacelle:** Montado no topo da nacelle para capturar vibrações da unidade geradora
4. **Dois acelerômetros nos rolamentos:** Instalados no rolamento dianteiro (*front bearing*) e traseiro (*rear bearing*) conforme mostrado na Figura B.3

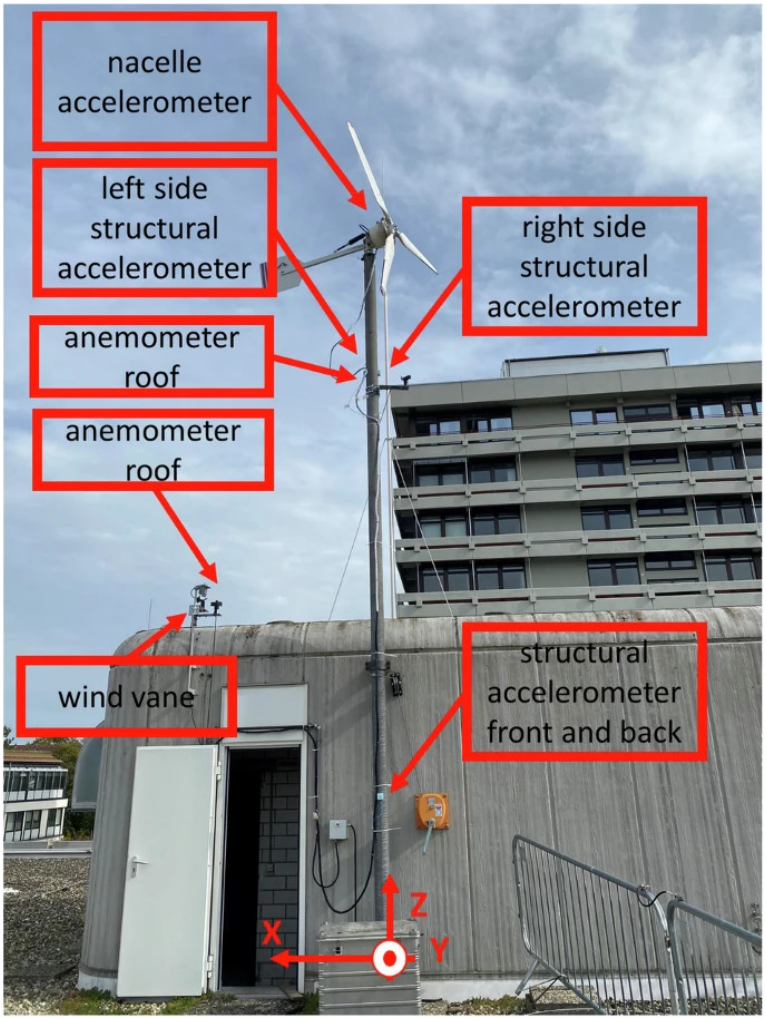

Figura B.2 Configuração dos sensores na turbina eólica Fraunhofer LBF. Sete acelerômetros triaxiais Brüel & Kjær 4524 distribuídos na estrutura: nacelle, laterais estruturais (esquerda/direita), anemômetros no teto, e sistema de coordenadas de referência (X, Y, Z). Fonte: Adaptado de Mostafavi e Friedmann (Mostafavi; Friedmann, 2024).

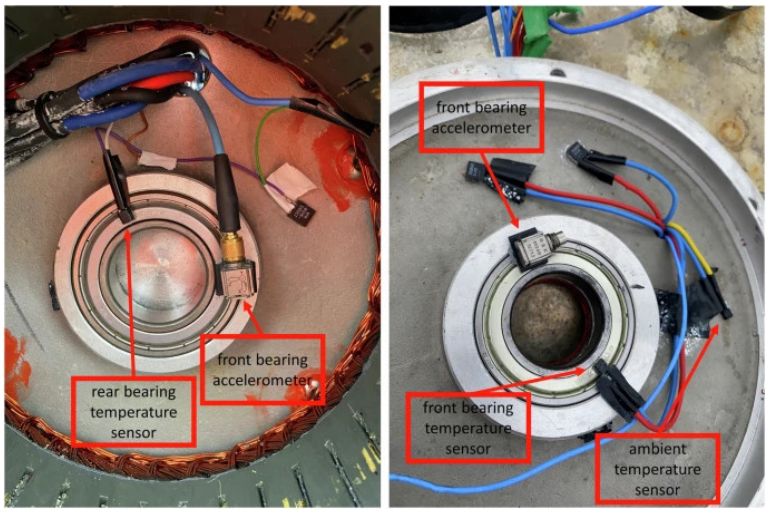

Figura B.3 Posicionamento dos acelerômetros nos rolamentos da turbina Fraunhofer LBF. (a) Esquerda: rolamento traseiro e posição do sensor. (b) Direita: rolamento dianteiro e posição do sensor. Sensores de temperatura também são visíveis (front bearing temperature sensor, rear bearing temperature sensor, ambient temperature sensor). Fonte: Adaptado de Mostafavi e Friedmann (Mostafavi; Friedmann, 2024).

Condições de Defeitos Implementados

O conjunto de dados implementa diversos cenários de danos, incluindo:

Tabela B.8 Cenários de defeitos implementados no dataset Fraunhofer LBF.

Tipo de Defeito	Descrição
Desbalanceamento de massa	Massa adicional no rotor
Desbalanceamento aerodinâmico	Alteração nas características das pás
Defeito na pista externa do rolamento	Dano localizado na pista externa
Defeito na pista interna do rolamento	Dano localizado na pista interna
Defeito no elemento rolante	Dano na superfície do elemento rolante

Condições Experimentais

Ambiente experimental: Os experimentos foram conduzidos em **condições ambientais reais** fora de um ambiente laboratorial controlado, introduzindo desafios como:

- **Velocidade variável do rotor** devido a flutuações naturais do vento
- **Ruído ambiental** de fontes externas não controladas
- **Sobrecargas** devido a rajadas de vento
- **Fatores ambientais** incluindo temperatura, umidade e condições climáticas

Implicações para validação: Esta variabilidade operacional confere maior **validade externa** aos resultados comparados a ensaios laboratoriais controlados, representando condições mais próximas à realidade industrial. No entanto, introduz desafios adicionais para algoritmos de diagnóstico, requerendo maior robustez a variações ambientais e operacionais.

Adequação para Aplicações de Pesquisa

O conjunto de dados demonstra particular adequação para:

- **Algoritmos de aprendizado de máquina** robustos a condições não estacionárias
- **Processamento de sinais** com técnicas de pré-processamento avançadas
- **Fusão de informações** através de sensores heterogêneos (vibração, temperatura, vento)
- **Abordagens multi-sensor** para monitoramento holístico
- **Quantificação de incerteza** devido à variabilidade inerente dos dados
- **Técnicas de pré-processamento de sinais** para lidar com ruído e artefatos ambientais

Localização: Fraunhofer Institute for Structural Durability and System Reliability LBF, Darmstadt, Hessen, 64289, Alemanha.

Disponibilidade: O dataset está disponível publicamente através da plataforma Zenodo com licença Creative Commons, permitindo a reprodutibilidade e a comparação com outros estudos.

B.5.9 Conjunto MFPT (Machinery Failure Prevention Technology)

O conjunto de dados MFPT foi desenvolvido pela Society for Machinery Failure Prevention Technology utilizando rolamentos rígidos de esferas fabricados pela NICE. O dataset compreende três condições operacionais: rolamentos saudáveis, defeitos de pista interna e defeitos de pista externa, coletados sob velocidade constante de 25 Hz e cargas variáveis.

Especificações Técnicas do Rolamento

Frequências Características

As frequências características de defeito para velocidade de rotação de 25 Hz são apresentadas na Tabela B.10.

Tabela B.9 Especificações geométricas do rolamento NICE (conjunto MFPT)

Parâmetro	Valor (mm)	Valor (pol)
Diâmetro primitivo (D_c)	31,62	1,245
Diâmetro das esferas (D_b)	5,97	0,235
Número de esferas (n)	8	
Ângulo de contato (ϕ)	0°	

Tabela B.10 Frequências características de defeito (conjunto MFPT, 25 Hz)

Tipo de Defeito	Sigla	Frequência (Hz)
Defeito de pista externa	ORDF	81,12
Defeito de pista interna	IRDF	118,88
Defeito de esfera	BDF	127,69
Defeito de gaiola	CRF	10,14

Configuração Experimental

O conjunto MFPT inclui 20 arquivos de vibração distribuídos conforme:

- **Rolamentos saudáveis:** 3 arquivos (N1–N3), 97.656 sps, 5 s, carga de 270 lbs
- **Defeitos de pista interna:** 7 arquivos (I1–I7), 48.828 sps, 3 s, cargas de 0–300 lbs
- **Defeitos de pista externa:** 10 arquivos (O1–O10), frequências de amostragem e durações variáveis, cargas de 25–300 lbs

O protocolo experimental manteve uma velocidade constante de 25 Hz, variando sistematicamente a carga aplicada para avaliação da robustez do diagnóstico sob diferentes condições operacionais.

B.5.10 Conjunto IMS (Center for Intelligent Maintenance Systems)

O conjunto de dados IMS foi desenvolvido pelo Center for Intelligent Maintenance Systems da University of Cincinnati como parte de estudos de degradação de rolamentos até falha completa. O conjunto de dados caracteriza-se por defeitos naturais resultantes de operação contínua até a falha, diferindo dos conjuntos com defeitos artificialmente induzidos.

Tabela B.11 Especificações geométricas e operacionais do rolamento Rexnord ZA-2115 utilizado no conjunto IMS

Parâmetro	Valor SI	Valor imperial / observação
Modelo: Rexnord ZA-2115		
Velocidade de rotação	33,33 Hz	2000 RPM
Diâmetro primitivo (P_d)	71,50 mm	2,815 pol
Diâmetro dos elementos rolantes (B_d)	8,41 mm	0,331 pol
Número de elementos rolantes (N)	16	
Ângulo de contato (ϕ)	0,264 rad	15,17°
Carga radial	26,7 kN	6000 lbs
Tipo de lubrificação	Lubrificação forçada	

Tabela B.12 Configuração de sensores (conjunto IMS)

Parâmetro	Set 1	Sets 2-3
Sensores por rolamento	2 (eixos x-y)	1
Total de canais	8	4
Modelo do sensor	PCB 353B33	PCB 353B33
Tipo	ICP acelerômetro	ICP acelerômetro
Sensibilidade	Alta	Alta

Especificações Técnicas do Rolamento

Instrumentação

Configuração Experimental

O conjunto IMS compreende três experimentos independentes até falha:

- **Set 1:** 2.156 arquivos, 8 canais, defeitos em rolamentos 3 e 4
- **Set 2:** 984 arquivos, 4 canais, defeito de pista externa no rolamento 1
- **Set 3:** 4.448 arquivos, 4 canais, defeito de pista externa no rolamento 3

Cada arquivo contém 20.480 pontos, adquiridos a 20 kHz, o que corresponde a uma duração de 1,024 s. A ordenação cronológica dos arquivos é definida diretamente pela marcação temporal incorporada aos nomes, permitindo acompanhar a evolução da degradação ao longo do ensaio.

Características dos Defeitos

Diferentemente dos demais conjuntos, o IMS apresenta defeitos resultantes de fadiga natural:

- **Progressão temporal**: Degradação gradual ao longo de semanas/meses

- **Múltiplos modos**: Defeitos de pista interna, externa e elemento rolante
- **Condições realistas**: Operação contínua sem intervenção
- **Documentação completa**: Cronologia detalhada da evolução

Esta característica torna o conjunto IMS particularmente adequado para validação de transferibilidade N→N (natural→natural) com outros conjuntos de defeitos por fadiga, como o Paderborn University.

Frequências Características Calculadas

Com base nas especificações geométricas e na velocidade operacional de 2000 RPM, as frequências características são:

Tabela B.13 Frequências características de defeito (conjunto IMS, calculadas)

Tipo de Defeito	Sigla	Frequência (Hz)	Fórmula
Defeito de pista externa	BPFO	∼236	$\frac{N \cdot n}{2}(1 - \frac{B_d}{P_d}\cos\phi)$
Defeito de pista interna	BPFI	∼297	$\frac{N \cdot n}{2}(1 + \frac{B_d}{P_d}\cos\phi)$
Defeito de elemento rolante	BSF	∼278	$\frac{P_d \cdot n}{2B_d}[1 - (\frac{B_d}{P_d}\cos\phi)^2]$
Defeito de gaiola	FTF	∼15	$\frac{n}{2}(1 - \frac{B_d}{P_d}\cos\phi)$

Onde n = 33,33 Hz (2000 RPM), N = 16 elementos, B_d = 8,41 mm, P_d = 71,50 mm e ϕ = 15,17.

Processamento para Transferibilidade

Para análise de transferibilidade, utilizou-se amostragem temporal esparsa do Set 1:

- **Amostragem**: 1 arquivo a cada 100 (44 amostras totais)
- **Labeling**: Baseado em progressão temporal
- **Classes**: baseline (0–70%), inner (70–90%), outer (90–100%)
- **Extração**: Features estatísticas por bearing (RMS, peak, mean)

Este protocolo preserva a representatividade temporal da degradação enquanto mantém viabilidade computacional para análise comparativa.

B.6 PSEUDOCÓDIGO DO FLUXO COMPLETO

O Algoritmo B.1 apresenta o fluxo completo de diagnóstico, desde o sinal bruto até a classificação final.

Algoritmo B.1: Fluxo completo de diagnóstico de falhas em rolamentos

Entrada: Sinal bruto $x[n]$, $n = 1, \ldots, N$; taxa de amostragem f_s
Saída: Classe predita $\hat{y} \in \{\text{Saudável, IR, OR, RE}\}$
// Pré-processamento
$x_{\text{filt}} \leftarrow \text{FiltroPassaFaixa}(x, f_{\text{baixa}} = 100 \text{ Hz}, f_{\text{alta}} = 10000 \text{ Hz})$
$x_{\text{norm}} \leftarrow (x_{\text{filt}} - \mu)/\sigma$ ▷ Normalização escore-Z

// Extração de características
Inicializar f = [] ▷ Vetor de características
// Domínio do caos
$(m, \tau) \leftarrow \text{ParametrosImersao}(x_{\text{norm}})$ ▷ FNN + AMI
$\lambda_{\max} \leftarrow \text{LyapunovRosenstein}(x_{\text{norm}}, m, \tau, f_s)$
$D_2 \leftarrow \text{DimensaoCorrelacao}(x_{\text{norm}}, m, \tau)$
$K_2 \leftarrow \text{EntropiaKolmogorov}(x_{\text{norm}}, m, \tau)$
$H \leftarrow \text{ExponenteHurst}(x_{\text{norm}})$
Adicionar $[\lambda_{\max}, D_2, K_2, H]$ a **f**

// Análise de recorrência
$(R, \varepsilon) \leftarrow \text{GraficoRecorrencia}(x_{\text{norm}}, m, \tau, \text{RR}_{\text{alvo}} = 0.05)$
$\text{RQA} \leftarrow \text{QuantificarRecorrencia}(R)$ ▷ RR, DET, LAM, etc.
Adicionar características RQA a **f**

// Entropia
para $r \in [0.1, 0.15, 0.2, 0.25, 0.3] \times \text{desvpad}(x_{\text{norm}})$ **faça**
    $\text{ApEn}_r \leftarrow \text{EntropiaAproximada}(x_{\text{norm}}, m = 2, r)$
    $\text{SampEn}_r \leftarrow \text{EntropiaAmostra}(x_{\text{norm}}, m = 2, r)$
    Adicionar $[\text{ApEn}_r, \text{SampEn}_r]$ a **f**
fim para

// Entropia multiescala
para $s \in [1, 2, 3, \ldots, 10]$ **faça**
    $x_s \leftarrow \text{Reamostrar}(x_{\text{norm}}, s)$
    $\text{MSE}_s \leftarrow \text{EntropiaAmostra}(x_s, m = 2, r = 0.2 \times \text{desvpad}(x_s))$

Adicionar MSE_s a **f**
fim para

// Análise multifractal
para $q \in [-5, -4, \ldots, 4, 5]$ **faça**
    $h(q) \leftarrow \text{MFDFA}(x_{\text{norm}}, q, m = 2)$
    Adicionar $h(q)$ a **f**
fim para
$\Delta\alpha \leftarrow \max(h) - \min(h)$ ▷ Largura espectro multifractal
Adicionar $\Delta\alpha$ a **f**

// Classificação
$\mathbf{f}_{\text{escal}} \leftarrow \text{PadronizadorEscala}(\mathbf{f})$ ▷ Normalização
$\hat{y} \leftarrow \text{GradienteImpulsionado}(\mathbf{f}_{\text{escal}})$

retornar $\hat{y}$

B.7 CONFIGURAÇÃO DE HIPERPARÂMETROS DO GRADIENT BOOSTING

B.7.1 Busca em Grade Realizada

Tabela B.14 Espaço de busca de hiperparâmetros para otimização via validação cruzada 5 dobras.

Hiperparâmetro	Valores testados	Valor ótimo
`n_estimadores`	[50, 100, 150, 200]	100
`taxa_aprendizado`	[0.01, 0.05, 0.1, 0.2]	0.1
`profundidade_max`	[3, 4, 5, 6, 8]	6
`min_amostras_divisao`	[2, 5, 10, 20]	5
`min_amostras_folha`	[1, 2, 4, 8]	2
`subamostra`	[0.6, 0.7, 0.8, 0.9, 1.0]	0.8
`caracteristicas_max`	[’raiz’, ’log2’, None]	’raiz’

Configuração final:

- 100 árvores de decisão
- Taxa de aprendizado 0.1 (controla a contribuição de cada árvore)
- Profundidade máxima 6 (mitiga o sobreajuste)
- Subamostragem 0.8 (80% das amostras por iteração, aumenta a robustez)

- Características por divisão: $\sqrt{d}$ onde $d = 288$ (número total de características)

Métrica de otimização: Acurácia balanceada (média das sensibilidades por classe).
Tempo de treinamento: $\approx$ 2.3 segundos (Intel i7-11800H, 32GB RAM).