



UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE TECNOLOGIA
CURSO DE GRADUAÇÃO EM ENGENHARIA MECÂNICA

ARTHUR DE ARANDAS RAMOS DINIZ

**ANÁLISE DE CONFIABILIDADE UTILIZANDO DISTRIBUIÇÕES DE
SOBREVIVÊNCIA E ALGORITMOS DE MACHINE LEARNING: UM ESTUDO DE
CASO SOBRE INJETORAS NA INDÚSTRIA CALÇADISTA**

João Pessoa
2025

ARTHUR DE ARANDAS RAMOS DINIZ

**ANÁLISE DE CONFIABILIDADE UTILIZANDO DISTRIBUIÇÕES DE
SOBREVIVÊNCIA E ALGORITMOS DE MACHINE LEARNING: UM ESTUDO DE
CASO SOBRE INJETORAS NA INDÚSTRIA CALÇADISTA**

Trabalho de Conclusão de Curso submetido à
Universidade Federal da Paraíba como requisito
à obtenção do título de Engenheiro Mecânico.

Orientador: Luciano Carlos Azevedo da Costa

João Pessoa
2025

Catálogo na publicação
Seção de Catalogação e Classificação

D585a Diniz, Arthur de Arandas Ramos.

Análise de confiabilidade utilizando distribuições de sobrevivência e algoritmos de machine learning: um estudo de caso sobre injetoras na indústria calçadista / Arthur de Arandas Ramos Diniz. - João Pessoa, 2025.
57 f. : il.

Orientação: Luciano Carlos Azevedo da Costa.
TCC (Graduação) - UFPB/CT.

1. Análise de Sobrevivência. 2. Aprendizado de Máquina. 3. Confiabilidade. 4. Modelos AFT. I. Costa, Luciano Carlos Azevedo da. II. Título.

UFPB/CT/BSCT

CDU 621(043.2)

ARTHUR DE ARANDAS RAMOS DINIZ

Análise de Confiabilidade Utilizando Distribuições de Sobrevivência e Algoritmos de Machine Learning: Um Estudo de Caso sobre Injetoras na Indústria Calçadista

Trabalho de Conclusão de Curso submetido à Coordenação de Graduação do Curso de Engenharia de Mecânica da UFPB, apresentado em sessão de defesa pública realizada em 23/04/2025, obtendo o conceito **Aprovado**, sob avaliação da banca examinadora a seguir:

Luciano Carlos Azevedo da Costa

Prof.º Dr. Luciano Carlos Azevedo da Costa - Orientador

DEP/CT/UFPB

Diego Paes de Andrade Pena

Prof.º Me. Diego Paes de Andrade Pena - Membro

DEM/CT/UFPB

Virgílio M. da Costa e Silva

Prof.º Me. Virgílio Mendonça da Costa e Silva - Membro

DEM/CT/UFPB

João Pessoa (PB)

2025

*Em memoria de Estrela, que ela descansa no
seio do Altissimo e de Lucineide, que o Senhor
se compadeça de sua alma.*

AGRADECIMENTOS

Este trabalho foi desenvolvido com o apoio de diversas pessoas, às quais expresso aqui minha sincera gratidão.

Ao Prof. Luciano Carlos Azevedo da Costa, por aceitar a orientação deste trabalho e por me introduzir à fascinante área da otimização.

Aos Professores Virgílio Mendonça da Costa e Silva e Diego Paes de Andrade Peña, minha gratidão por aceitarem prontamente o convite para compor a banca examinadora e por dedicarem seu tempo à avaliação deste trabalho. A participação de vocês é muito valiosa neste momento especial da minha formação.

A Romário, por todo o apoio prestado durante a elaboração deste trabalho.

Ao colega de curso Arthur Ferreira, pela ajuda na formatação e revisão deste trabalho.

A Carlos Henrique Moraes, por me motivar a seguir o caminho da Engenharia.

Aos integrantes do Curso de Graduação em Engenharia Mecânica do Centro de Tecnologia da Universidade Federal da Paraíba, pela formação profissional de alto nível oferecida.

À minha família, cujo apoio, compreensão e incentivo me permitiram chegar ao fim deste curso.

E a todos aqueles que, direta ou indiretamente, contribuíram para a realização deste trabalho e para o meu aperfeiçoamento pessoal e profissional.

“O que foi, é e sempre será.”

RESUMO

A confiabilidade de máquinas injetoras na indústria calçadista é crucial, sendo a previsão precisa de falhas um desafio relevante para a manutenção preditiva. Este trabalho aborda a comparação de métodos de análise de sobrevivência neste contexto. Objetiva-se comparar a Precisão Preditiva de abordagens tradicionais (paramétricas) e de Aprendizado de Máquina (AM) na estimativa da probabilidade de falha, identificando a metodologia mais adequada. Aplica-se análise de sobrevivência a dados reais de manutenção coletados entre janeiro de 2023 e dezembro de 2024. Implementam-se e otimizam-se modelos *Weibull AFT*, *Lognormal AFT*, *Random Survival Forest (RSF)* e *Gradient Boosting Survival (GBS)*. Avalia-se a acurácia por meio de métricas como C-index e Brier Score em dados de teste, e analisa-se a importância das variáveis nos modelos de AM. Os resultados indicam superioridade preditiva do AM, especialmente do GBS, sobre os modelos paramétricos testados, demonstrando maior flexibilidade na adaptação aos padrões dos dados observados. Conclui-se que o AM é uma alternativa promissora para otimizar a previsão de falhas e o planejamento da manutenção neste cenário industrial.

Palavras-chave: Análise de Sobrevivência; Aprendizado de Máquina; Confiabilidade; Modelos AFT.

ABSTRACT

The reliability of injection molding machines in the footwear industry is crucial, with accurate failure prediction being a significant challenge for predictive maintenance. This study examines the comparison of survival analysis methods in this context. The objective is to compare the predictive accuracy of traditional (parametric) approaches and Machine Learning (ML) techniques in estimating failure probability, identifying the most suitable methodology. Survival analysis is applied to real maintenance data collected between January 2023 and December 2024. Weibull AFT, Lognormal AFT, Random Survival Forest (RSF), and Gradient Boosting Survival (GBS) models are implemented and optimized. Accuracy is assessed using metrics such as C-index and Brier Score on test data, and the importance of variables in ML models is analyzed. The results indicate the predictive superiority of ML, particularly GBS, over the parametric models tested, demonstrating greater flexibility in adapting to observed data patterns. It is concluded that ML is a promising alternative for optimizing failure prediction and maintenance planning in this industrial scenario.

Keywords: Survival Analysis; Machine Learning; Reliability; AFT Models.

LISTA DE FIGURAS

| | |
|--|----|
| Figura 1 – Tipos de aprendizado. | 23 |
| Figura 2 – Representação de uma árvore de decisão. | 25 |
| Figura 3 – Ilustração de um algoritmo de Random Survival Forest | 27 |
| Figura 4 – Ilustração de um algoritmo de Gradient Boosting Machine | 29 |
| Figura 5 – Hold-out | 31 |
| Figura 6 – K-Fold | 32 |
| Figura 7 – Ilustração dos modelos de máquinas injetoras por fabricante (imagens baseadas nos manuais). | 38 |
| Figura 8 – Pré e Visualização dos dados | 39 |
| Figura 9 – Outliers | 40 |
| Figura 10 – Histograma de TTF por fabricante | 43 |
| Figura 11 – Histograma de TTF por processo | 44 |
| Figura 12 – Histograma de TTF Geral | 44 |
| Figura 13 – Matriz de Correlação TTR-TTF | 45 |
| Figura 14 – Curvas de Sobrevivência - Modelos Paramétricos | 46 |
| Figura 15 – Curvas de Sobrevivência por Processos - Modelos Paramétricos | 46 |
| Figura 16 – Curva de Sobrevivência - RSF | 49 |
| Figura 17 – Curva de Sobrevivência - GBS | 49 |
| Figura 18 – Curvas de Sobrevivência por Processos - RSF | 50 |
| Figura 19 – Curvas de Sobrevivência por Processos- GBS | 50 |
| Figura 20 – Comparação das Curvas de Sobrevivência Médias Estimadas pelos Modelos | 52 |

LISTA DE TABELAS

| | |
|---|----|
| Tabela 1 – Comparação entre GBS e RSF | 30 |
| Tabela 2 – Comparação entre IBS e C-index | 35 |
| Tabela 3 – Descrição das Variáveis Seleccionadas | 36 |
| Tabela 4 – Hiperparâmetros Utilizados na Busca para Modelos RSF e GBS | 42 |
| Tabela 5 – Hiperparâmetros Otimizados - RSF e GBS | 42 |
| Tabela 6 – Desempenho dos Modelos Weibull e Lognormal | 45 |
| Tabela 7 – Resultados Completos do Modelo Weibull Ajustado | 47 |
| Tabela 8 – Resultados Completos do Modelo Lognormal Ajustado | 47 |
| Tabela 9 – Desempenho dos Modelos GBS e RSF | 48 |
| Tabela 10 – Comparativo da Importância das <i>Features</i> por Permutação para Modelos RSF e GBS | 48 |
| Tabela 11 – Ganho Percentual de Desempenho dos Modelos de AM sobre Modelos Tradicionais (Conjunto de Teste) | 51 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|-----|------------------------------|
| AM | Aprendizado de Máquina |
| GBM | Gradient Boosting Machine |
| GBS | Gradient Boosting Survival |
| KNN | K-Nearest Neighbors |
| RF | Random Florest |
| RSF | Random Survival Florest |
| RUL | Vida Útil Restante |
| SVM | Support Vector Machine |
| TPM | Total Productive Maintenance |
| WCM | World Class Manufacturing |

SUMÁRIO

| | | |
|--------------|--|-----------|
| 1 | INTRODUÇÃO | 13 |
| 1.1 | Definição do Tema | 13 |
| 1.2 | Justificativa | 16 |
| 1.3 | Objetivos | 17 |
| <i>1.3.1</i> | <i>Objetivo Geral</i> | <i>17</i> |
| <i>1.3.2</i> | <i>Objetivos Específicos</i> | <i>17</i> |
| 1.4 | Organização do trabalho | 18 |
| 2 | REFERENCIAL TEÓRICO | 19 |
| 2.1 | Análise de Confiabilidade | 19 |
| <i>2.1.1</i> | <i>Análise Estatística de Confiabilidade</i> | <i>19</i> |
| <i>2.1.2</i> | <i>Tempo até a falha</i> | <i>19</i> |
| <i>2.1.3</i> | <i>Função Confiabilidade</i> | <i>20</i> |
| <i>2.1.4</i> | <i>Função Taxa de Falha</i> | <i>20</i> |
| 2.2 | Distribuições Aplicadas a Confiabilidade | 21 |
| <i>2.2.1</i> | <i>Distribuição Lognormal</i> | <i>21</i> |
| <i>2.2.2</i> | <i>Distribuição Weibull</i> | <i>22</i> |
| 2.3 | Aprendizagem de Máquina | 23 |
| <i>2.3.1</i> | <i>Tipos de Aprendizagem</i> | <i>23</i> |
| <i>2.3.2</i> | <i>Modelos de Aprendizado de Máquina Aplicados à Análise de Confiabilidade</i> | <i>24</i> |
| <i>2.3.3</i> | <i>Métodos baseados em Árvores</i> | <i>24</i> |
| <i>2.3.4</i> | <i>Random Survival Forest (RSF)</i> | <i>26</i> |
| <i>2.3.5</i> | <i>Gradient Boosting Survival (GBS)</i> | <i>28</i> |
| <i>2.3.6</i> | <i>Comparação entre RSF e GBS</i> | <i>30</i> |
| 2.4 | Validação de Modelos de Aprendizado de Máquina | 31 |
| <i>2.4.1</i> | <i>Hold-out</i> | <i>31</i> |
| <i>2.4.2</i> | <i>Validação Cruzada</i> | <i>32</i> |
| 2.5 | Estatísticas de Desempenho | 33 |
| <i>2.5.1</i> | <i>Índice Integrado de Brier (IBS)</i> | <i>33</i> |
| <i>2.5.2</i> | <i>C-index</i> | <i>34</i> |
| <i>2.5.3</i> | <i>Comparação entre C-Index e Integrated Brier Score</i> | <i>35</i> |
| 3 | MATERIAIS E MÉTODOS | 36 |
| 3.1 | Base de Dados | 36 |
| <i>3.1.1</i> | <i>Seleção das Variáveis</i> | <i>36</i> |
| <i>3.1.2</i> | <i>Caracterização dos Equipamentos</i> | <i>37</i> |
| 3.2 | Pré-carregamento e Tratamento dos Dados | 39 |
| 3.3 | Modelos | 40 |
| <i>3.3.1</i> | <i>Modelagem Paramétrica</i> | <i>40</i> |

| | | |
|-------|---|----|
| 3.3.2 | <i>Modelagem de Aprendizado de Máquina</i> | 41 |
| 4 | RESULTADOS E DISCUSSÕES | 43 |
| 4.1 | Análise do Comportamento do Tempo de Falha | 43 |
| 4.2 | Resultado dos Modelos Paramétricos | 45 |
| 4.3 | Resultado dos Modelos de Aprendizado de Máquina | 47 |
| 4.4 | Análise Comparativa: Modelos Paramétricos vs. Aprendizado de Máquina | 51 |
| 5 | CONCLUSÃO | 54 |
| | REFERÊNCIAS | 55 |

1 INTRODUÇÃO

1.1 Definição do Tema

A manutenção industrial deixou de ser vista meramente como uma atividade de reparo para se consolidar como um elemento estratégico vital na engenharia de produção e gestão de ativos. Em um mercado globalizado e altamente competitivo, a capacidade de uma organização garantir a operacionalidade contínua e eficiente de seus equipamentos e instalações não é apenas um diferencial, mas uma necessidade para a sobrevivência e prosperidade do negócio. A gestão estratégica da manutenção engloba um conjunto integrado de técnicas e práticas que visam maximizar a disponibilidade, a confiabilidade e a segurança dos ativos físicos, ao mesmo tempo em que se otimizam os custos totais de ciclo de vida e se suporta os objetivos gerais da organização, como qualidade do produto e pontualidade nas entregas (Sá, 2021). Essa visão estratégica reconhece que a performance da manutenção impacta diretamente indicadores chave de desempenho (KPIs) e a competitividade geral da empresa.

Contudo, a implementação de estratégias de manutenção eficazes enfrenta desafios crescentes. A complexidade tecnológica dos equipamentos modernos, a pressão constante por redução de custos e aumento de produtividade, a integração de sistemas ciber-físicos e a necessidade de lidar com múltiplos modos de falha e fatores de degradação (operacionais, ambientais) tornam o planejamento e a execução da manutenção tarefas intrinsecamente complexas. Abordagens tradicionais, como a manutenção corretiva (agir após a falha) ou a preventiva baseada em intervalos fixos (manutenções periódicas independentes da condição real), frequentemente se mostram subótimas, levando a custos elevados com paradas não planejadas ou a intervenções prematuras e desperdício de vida útil remanescente de componentes. Torna-se imperativo, portanto, adotar abordagens mais inteligentes, proativas e baseadas em dados para a tomada de decisão em manutenção.

Neste contexto, a Engenharia de Confiabilidade fornece o arcabouço teórico e metodológico fundamental. Trata-se da disciplina que aplica princípios de engenharia e, crucialmente, métodos estatísticos para avaliar, prever e melhorar a capacidade de um item (componente, equipamento ou sistema) desempenhar sua função requerida sem falhas, por um período de tempo determinado, sob condições operacionais especificadas (Lafraia, 2001). Compreender quantitativamente a confiabilidade – ou a falta dela – é o primeiro passo para gerenciá-la. A análise estatística dos dados de vida e falha dos equipamentos é, portanto, central para a engenharia de confiabilidade.

A principal ferramenta para realizar essa análise é a **Análise de Sobrevivência**, um conjunto de métodos estatísticos robustos, inicialmente desenvolvidos em áreas como a biometria e ciências atuariais, mas hoje amplamente aplicados na engenharia para modelar o tempo até a ocorrência de um evento – no nosso caso, a falha de um equipamento industrial. Ao estudar o tempo até a falha, a Análise de Sobrevivência permite estimar funções essenciais como a função de sobrevivência (ou confiabilidade), $S(t)$, que representa a probabilidade de um item operar

sem falhas até um instante t , e a função de taxa de falha (ou função de risco), $h(t)$, que descreve o risco instantâneo de falha no tempo t , dado que o item sobreviveu até então. A forma da função de taxa de falha ao longo do tempo (constante, crescente, decrescente, ou a combinação conhecida como "curva da banheira") fornece insights valiosos sobre os mecanismos de falha predominantes (falhas prematuras, aleatórias, por desgaste) e orienta diretamente as estratégias de manutenção mais adequadas (Barbosa, 2016). Assim, a Análise de Sobrevivência constitui o núcleo metodológico da **Análise Estatística da Confiabilidade** quando o foco reside na modelagem do tempo de vida e na previsão de falhas.

Historicamente, essa análise estatística da confiabilidade tem se baseado em modelos paramétricos. Estes modelos assumem que o tempo até a falha segue uma distribuição de probabilidade teórica específica, cujos parâmetros são estimados a partir dos dados observados. Dentre as diversas distribuições disponíveis, a distribuição de Weibull e a Lognormal ganharam grande popularidade na engenharia de confiabilidade. A distribuição de Weibull é particularmente versátil devido à capacidade de seu parâmetro de forma (β) ajustar a função de taxa de falha para representar falhas decrescentes ($\beta < 1$), constantes ($\beta = 1$, equivalente à exponencial) ou crescentes ($\beta > 1$), cobrindo assim as diferentes fases da "curva da banheira" (Filho, Sisquini e Barbosa, 2023; Revista Manutenção, 2023). A distribuição Lognormal, por sua vez, é frequentemente associada a processos de falha multiplicativos ou relacionados a fadiga e desgaste (Revista Manutenção, 2023). A estimação dos parâmetros dessas distribuições (como os parâmetros de forma e escala da Weibull, ou a média e desvio padrão da Lognormal) a partir de dados históricos de falha permite caracterizar a confiabilidade do equipamento e fazer previsões sobre seu comportamento futuro, informando decisões sobre intervalos de inspeção, políticas de substituição e níveis de estoque de peças sobressalentes.

O cenário da análise de confiabilidade, no entanto, vem sendo transformado pela revolução digital e pela Indústria 4.0. A capacidade de coletar, armazenar e processar grandes volumes de dados em tempo real, provenientes de sensores embarcados (monitorando vibração, temperatura, pressão, corrente elétrica, etc.), sistemas supervisórios (SCADA) e bancos de dados de manutenção (CMMS), criou oportunidades sem precedentes para o desenvolvimento de modelos preditivos mais sofisticados (Gogoberidze, 2023). Frequentemente, a falha de um equipamento não depende apenas do tempo de operação, mas de uma complexa interação entre múltiplas variáveis operacionais, condições ambientais e histórico de manutenção. Modelos estatísticos tradicionais podem ter dificuldade em capturar essas interações complexas ou podem exigir simplificações e suposições que nem sempre se verificam na prática.

É neste ponto que o Aprendizado de Máquina (Machine Learning - AM) oferece um paradigma alternativo e complementar. Sendo um subcampo da Inteligência Artificial, o AM engloba algoritmos projetados para aprender padrões e relações diretamente a partir dos dados, sem depender de modelos matemáticos pré-especificados ou fortes suposições distribucionais (Faceli *et al.*, 2021). Aplicado à manutenção preditiva e à análise de confiabilidade, o AM tem o potencial de identificar padrões sutis e não lineares nos dados de sensores e operação que

podem ser precursores de falhas, levando a previsões potencialmente mais acuradas e específicas à condição real do equipamento (Xue *et al.*, 2025).

Dentro do vasto campo do AM, foram desenvolvidas ou adaptadas técnicas específicas para lidar com dados de tempo até o evento, características da análise de sobrevivência. Modelos baseados em conjuntos (*ensemble methods*), que combinam as previsões de múltiplos modelos mais simples (geralmente árvores de decisão) para obter uma predição final mais robusta e precisa, mostraram-se particularmente promissores. O *Random Survival Forest* (RSF) (Ishwaran *et al.*, 2008), uma adaptação do popular algoritmo *Random Forest*, constrói múltiplas árvores de sobrevivência em subamostras dos dados e das variáveis, agregando seus resultados para estimar a função de risco acumulado. O *Gradient Boosting Survival* (GBS), por sua vez, aplica a técnica de *gradient boosting* (Friedman, 2001), construindo árvores sequencialmente onde cada nova árvore tenta corrigir os erros da combinação anterior, adaptado para otimizar uma função de perda adequada para dados de sobrevivência. Estes métodos são inerentemente não paramétricos, flexíveis para capturar interações complexas e não lineares, e têm demonstrado desempenho competitivo ou superior aos modelos tradicionais em diversas aplicações (Graf, Todd e Baksh, 2025; Zhang *et al.*, 2022; Saeed *et al.*, 2024).

A existência dessas duas abordagens – a estatística paramétrica tradicional e o aprendizado de máquina para sobrevivência – levanta uma questão relevante para a prática e a pesquisa em engenharia de confiabilidade: Qual abordagem é mais eficaz para prever falhas em um determinado contexto industrial real? A maior flexibilidade do AM se traduz, de fato, em uma melhor acurácia preditiva que justifique sua (por vezes maior) complexidade computacional e menor interpretabilidade direta em comparação com modelos como Weibull ou Lognormal?

Este trabalho de conclusão de curso busca endereçar precisamente essa questão através de um estudo de caso empírico. O foco será direcionado a um tipo específico de equipamento industrial – máquinas injetoras – operando em um setor relevante – a indústria calçadista. Este estudo de caso se baseia em dados coletados na totalidade de uma importante planta fabril do setor calçadista, analisando o histórico completo de suas 189 máquinas injetoras, proporcionando assim uma base empírica ampla e representativa para a investigação. As injetoras são componentes vitais neste setor, responsáveis pela moldagem de peças como solados e entressolas, e operam sob condições de alta demanda e ciclos repetitivos, tornando sua confiabilidade um fator crítico para a manutenção do fluxo produtivo e a competitividade das empresas. A análise de dados reais de falhas provenientes desses equipamentos oferece uma oportunidade valiosa para comparar o desempenho preditivo das abordagens clássicas e modernas de análise de sobrevivência.

Assim, o **problema** que norteia esta pesquisa é definido pela seguinte pergunta: **Qual abordagem metodológica – entre os modelos tradicionais de análise de sobrevivência baseados em tempo de falha acelerado (AFT) com distribuições Weibull e Lognormal, e os algoritmos de aprendizado de máquina para análise de sobrevivência *Random Survival Forest* (RSF) e *Gradient Boosting Survival* (GBS) – proporciona maior precisão na estimativa da probabilidade de sobrevivência ao longo do tempo para máquinas injetoras na indústria**

calçadista, quando aplicadas a um conjunto de dados reais de histórico de falhas (coletado entre janeiro de 2023 e dezembro de 2024)? A investigação se concentrará na comparação objetiva da performance preditiva, utilizando métricas apropriadas, com o intuito de fornecer subsídios para a escolha de modelos e a otimização de estratégias de manutenção neste contexto industrial, sem aprofundar nas causas físicas específicas das falhas analisadas.

1.2 Justificativa

A motivação para este estudo assenta-se tanto na relevância prática e econômica de aprimorar a manutenção industrial quanto na importância acadêmica e metodológica de comparar abordagens tradicionais e modernas de análise de confiabilidade em contextos específicos.

Do ponto de vista **prático e econômico**, a otimização da manutenção é um fator crítico para a sustentabilidade e lucratividade industrial. Paradas não planejadas de equipamentos essenciais, como as máquinas injetoras no setor calçadista, acarretam custos diretos (peças, mão de obra emergencial) e indiretos (perda de produção, atrasos, impacto na cadeia logística) substanciais. Relatórios da indústria, como os compilados pela Abecom (2022) citando índices da Fortune Global 500, estimam que os custos de paradas não planejadas podem alcançar até 8% da receita anual em grandes corporações (Abecom, 2022). A implementação de estratégias de manutenção preditiva, que dependem de previsões acuradas de falha, visa mitigar esses custos, permitindo intervenções proativas que maximizam a disponibilidade do equipamento e a eficiência operacional. Portanto, a busca por modelos que ofereçam maior precisão na previsão do tempo até a falha tem um impacto econômico direto e significativo, justificando a investigação de novas abordagens como o AM.

Do ponto de vista **acadêmico e metodológico**, este trabalho contribui para a discussão comparativa entre modelos estatísticos tradicionais e técnicas de Aprendizado de Máquina na análise de sobrevivência industrial. As distribuições Weibull e Lognormal são ferramentas consolidadas e amplamente utilizadas na engenharia de confiabilidade há décadas, com vasta literatura documentando sua aplicação, como exemplificado por (Filho, Sisquini e Barbosa, 2023). Seus pontos fortes residem na interpretabilidade dos parâmetros e na fundamentação teórica. Contudo, suas premissas podem ser restritivas em cenários com múltiplas covariáveis e interações complexas. O Aprendizado de Máquina, por sua vez, oferece flexibilidade para modelar tais cenários complexos (Gogoberidze, 2023; Xue *et al.*, 2025). Algoritmos como RSF e GBS vêm sendo explorados em diversas áreas, inclusive na análise de confiabilidade de sistemas e componentes (como na aplicação de RSF em deterioração de pontes e equipamentos médicos complexos, conforme estudos citados em (Lu e Guler, 2022)).

Estudos comparativos diretos entre essas classes de modelos em contextos de confiabilidade são de grande interesse acadêmico. Pesquisas recentes têm comparado, por exemplo, o desempenho do RSF com o modelo de Cox (Graf, Todd e Baksh, 2025) ou com o modelo AFT-Weibull (Lu e Guler, 2022), frequentemente apontando para uma melhor capacidade discriminativa dos modelos de AM (via C-index), embora a calibração possa variar. No entanto,

ainda há espaço para investigações empíricas em diferentes setores industriais e tipos de equipamentos, como o proposto neste trabalho (máquinas injetoras na indústria calçadista). Muitos estudos de AM em manutenção ainda focam em classificação ou regressão de RUL (Vida Útil Remanescente), tornando relevante a comparação específica dentro do âmbito da análise de sobrevivência.

Adicionalmente, existe uma oportunidade de contribuir para a literatura científica em língua portuguesa, onde estudos empíricos detalhados comparando essas abordagens com dados reais da indústria nacional podem ser menos frequentes, facilitando a disseminação do conhecimento para estudantes e profissionais no Brasil.

Em suma, este estudo justifica-se por:

- **Enfrentar um problema industrial relevante:** A otimização da manutenção de injetoras através de melhores previsões de falha impacta diretamente custos e eficiência na indústria calçadista.
- **Contribuir com evidência empírica:** Avaliar empiricamente o desempenho de modelos estatísticos tradicionais versus modelos de AM para sobrevivência (RSF, GBS) usando dados reais e métricas apropriadas (C-index, Brier Score).
- **Investigar um contexto específico:** Aplicar e validar essas abordagens em um cenário (injetoras/calçadista) que pode ter particularidades não cobertas por estudos em outros setores.
- **Agregar à literatura:** Fornecer resultados que informem a escolha de modelos para análise de confiabilidade e planejamento de manutenção, com potencial contribuição para a comunidade de língua portuguesa.

Espera-se que os resultados desta comparação forneçam insights valiosos sobre a aplicabilidade e o desempenho relativo das abordagens estatísticas e de aprendizado de máquina para a análise de confiabilidade neste contexto industrial.

1.3 Objetivos

1.3.1 *Objetivo Geral*

Realizar uma análise comparativa entre abordagens tradicionais de análise de sobrevivência e técnicas de Aprendizado de Máquina para avaliar qual oferece maior precisão na estimativa da probabilidade de sobrevivência (ou falha) ao longo do tempo para máquinas injetoras em uma indústria calçadista.

1.3.2 *Objetivos Específicos*

- Caracterizar os padrões de falha das máquinas injetoras através da análise exploratória dos dados de TTF.
- Implementar e avaliar a acurácia de modelos paramétricos de sobrevivência (Weibull AFT, Lognormal AFT) na predição das probabilidades de sobrevivência.

- Implementar, otimizar e avaliar a acurácia de modelos de Aprendizado de Máquina para sobrevivência (RSF, GBS) na predição das probabilidades de sobrevivência.
- Comparar a utilização e a importância atribuída às variáveis preditoras por cada abordagem metodológica na modelagem da probabilidade de sobrevivência.
- Identificar, com base na comparação de acurácia (C-index, Brier Score) e características, a abordagem mais adequada para a predição da probabilidade de sobrevivência/falha neste contexto.

1.4 Organização do trabalho

Este estudo está estruturado em cinco capítulos, organizados da seguinte forma:

- **Capítulo 1 - Introdução:** Apresenta o tema central do estudo, contextualiza o problema de pesquisa, justifica a relevância da investigação, define os objetivos geral e específicos, e detalha a organização do documento.
- **Capítulo 2 - Referencial Teórico:** Revisa e discute os conceitos fundamentais que embasam a pesquisa, incluindo análise de confiabilidade, métodos de análise de sobrevivência (paramétricos e de aprendizado de máquina) e métricas de avaliação de desempenho.
- **Capítulo 3 - Materiais e Métodos:** Descreve detalhadamente a origem e o tratamento da base de dados utilizada, as ferramentas computacionais empregadas, e os procedimentos passo a passo para a implementação, otimização e avaliação dos modelos estatísticos e de aprendizado de máquina.
- **Capítulo 4 - Resultados e Discussão:** Apresenta os resultados obtidos a partir da aplicação dos modelos aos dados, incluindo análises exploratórias, métricas de desempenho, comparação entre as abordagens e uma discussão aprofundada das implicações desses achados.
- **Capítulo 5 - Conclusão:** Sintetiza as principais contribuições e descobertas do trabalho, retoma os objetivos e a questão de pesquisa, discute as limitações do estudo e propõe direções para pesquisas futuras na área.

2 REFERENCIAL TEÓRICO

Nesta seção, são apresentados os principais conceitos e terminologias relacionados à análise de sobrevivência aplicada à confiabilidade de ativos industriais. Também são abordados fundamentos de aprendizado de máquina, focando em sua aplicação na análise de sobrevivência.

2.1 Análise de Confiabilidade

A análise de confiabilidade é uma área da engenharia que avalia a capacidade de sistemas e componentes de operarem sem falhas durante um período específico e em condições determinadas. Segundo (Lafraia, 2001), a confiabilidade é a probabilidade de que um sistema execute suas funções conforme o esperado, sem falhas, durante um intervalo de tempo. Em projetos de engenharia, essa análise é crucial para otimizar a durabilidade e a segurança dos produtos, influenciando diretamente o desenvolvimento de estratégias de manutenção e operação.

No contexto de projetos, a confiabilidade torna-se um fator estratégico. Métodos como a Análise de Modos e Efeitos de Falha (FMEA) e a Análise de Árvore de Falhas (FTA) são amplamente utilizados para identificar potenciais falhas e suas causas. Dhillon (2006) destaca que essas técnicas ajudam os engenheiros a prever falhas e a tomar decisões preventivas antes do lançamento do produto. Isso garante sistemas mais robustos e eficientes, resultando em menores custos de manutenção e em uma maior vida útil.

2.1.1 Análise Estatística de Confiabilidade

O foco deste trabalho está na análise estatística de confiabilidade, que utiliza métodos matemáticos para prever o comportamento de falhas ao longo do tempo. Uma das ferramentas mais importantes nesse contexto é a análise de sobrevivência, que estuda o tempo até a ocorrência de eventos, como falhas de componentes ou sistemas (Colosimo e Giolo, 2024). Essa técnica é especialmente útil quando lidamos com dados censurados, ou seja, quando nem todas as falhas foram observadas dentro do período de análise (Karim e Islam, 2019). Por essa razão, a análise de sobrevivência é fundamental na confiabilidade; ela permite trabalhar com dados incompletos, tornando os resultados mais realistas.

2.1.2 Tempo até a falha

O tempo de falha de um item é definido como o tempo transcorrido desde o momento em que o item é colocado em operação até o instante de sua falha. Conforme ressaltam Pham (2022), a análise do tempo de falha permite modelar e prever o comportamento de sistemas, possibilitando uma melhor compreensão dos fatores que influenciam a sua confiabilidade. O tempo de falha pode ser descrito matematicamente pela variável aleatória T , onde T representa o tempo até a falha de um sistema.

A função de densidade de probabilidade (FDP) do tempo de falha, $f(t)$, é expressa como:

$$f(t) = \frac{d}{dt}F(t) \quad (1)$$

Aqui, $F(t)$ é a função de distribuição acumulada do tempo de falha, que representa a probabilidade de que a falha ocorra até um tempo t .

2.1.3 Função Confiabilidade

A função $R(t)$, que determina a probabilidade de um item não apresentar falhas no intervalo de tempo $(0, t)$ e continuar operando no instante t , é chamada de função de confiabilidade, também conhecida como função de sobrevivência (Pham, 2022). Ela é formalmente definida como:

$$R(t) = P(T > t), \quad t > 0 \quad (2)$$

onde T representa a variável aleatória que denota o tempo até a falha do sistema. Em outras palavras, a função de confiabilidade indica a probabilidade de que um item não falhe até o tempo t .

A função de confiabilidade também pode ser expressa como o complemento da função de falha acumulada $F(t)$, que representa a probabilidade de falha até o tempo t . A relação entre essas funções é dada por:

$$R(t) = 1 - F(t) \quad (3)$$

Conforme discutido por O'Connor, Moddares e Moslen (2016), a função de confiabilidade pode ser modelada utilizando diferentes distribuições estatísticas, dependendo do comportamento do sistema. Nelson (2004) também ressalta que a função de confiabilidade é essencial para prever o desempenho de sistemas em diferentes condições operacionais, sendo amplamente empregada na definição de estratégias de manutenção e no planejamento de ações corretivas e preventivas.

2.1.4 Função Taxa de Falha

A função taxa de falha é um conceito central na análise de confiabilidade, descrevendo a frequência com que falhas ocorrem em um item durante um determinado período de operação. É importante destacar que a taxa de falha não deve ser confundida com a probabilidade de falha. Enquanto a probabilidade indica a chance de uma falha ocorrer em um intervalo específico, a taxa de falha mede a ocorrência de falhas por unidade de tempo (Colosimo e Giolo, 2024). Matematicamente, a função taxa de falha $\lambda(t)$ pode ser expressa como:

$$\lambda(t) = \frac{f(t)}{R(t)} \quad (4)$$

onde $f(t)$ é a função de densidade de probabilidade do tempo de falha e $R(t)$ é a função de confiabilidade. Essa equação mostra que a taxa de falha em um instante t é proporcional à probabilidade de falha naquele momento, em relação à probabilidade de o sistema ainda estar funcionando.

Ye *et al.* (2020) enfatizam que a análise da taxa de falha é essencial para entender como um item se comporta ao longo do tempo. Nelson (2004) complementa essa ideia, destacando a importância de monitorar a taxa de falha para prever e planejar ações de manutenção. Cheng, Wei e Liao (2022) contribuem para essa discussão ao abordar a relação entre confiabilidade e

resiliência em sistemas complexos, ressaltando que a compreensão da taxa de falha é vital para a análise do desempenho de tais sistemas. Além disso, Thompson e Barriga (2019) discutem como a taxa de falha pode variar conforme o envelhecimento dos equipamentos, com Takahashi (2023) mostrando que, geralmente, a taxa tende a aumentar à medida que o item se aproxima do fim de sua vida útil.

2.2 Distribuições Aplicadas a Confiabilidade

As técnicas de análise estatística de confiabilidade são classificadas em três grupos: paramétricas, semiparamétricas e não paramétricas. Os modelos paramétricos são amplamente utilizados porque assumem que o tempo até a falha segue uma distribuição de probabilidade específica. A alta flexibilidade desses métodos se deve à capacidade de ajuste dos parâmetros da distribuição, permitindo que o modelo se adapte bem aos dados observados (Colosimo e Giolo, 2024). Essa característica é especialmente importante em cenários industriais, onde é necessário prever com precisão o comportamento de falhas.

Neste trabalho, optou-se por métodos paramétricos devido à sua eficácia no ajuste de dados de falhas industriais (Lafraia, 2001). Distribuições como a Weibull e log-normal são amplamente utilizadas, pois oferecem flexibilidade para representar diferentes padrões de falha, conforme apontado por Pham (2022).

2.2.1 Distribuição Lognormal

A distribuição lognormal é uma ferramenta essencial na análise de confiabilidade, amplamente utilizada para modelar o tempo até a falha de componentes, especialmente quando os dados apresentam assimetria e alta variabilidade. Essa distribuição é aplicável quando o logaritmo do tempo até a falha segue uma distribuição normal, sendo útil para descrever fenômenos como o desgaste de materiais e a vida útil de produtos.

A função de densidade de probabilidade (FDP) da distribuição lognormal é dada por:

$$f(t) = \frac{1}{t\sigma\sqrt{2\pi}} e^{-\frac{(\ln t - \mu)^2}{2\sigma^2}}, \quad t > 0 \quad (5)$$

onde μ é a média e σ é o desvio padrão do logaritmo do tempo até a falha. A função de sobrevivência, que representa a probabilidade de um sistema continuar operando sem falhas até um tempo t , é expressa como:

$$S(t) = 1 - \Phi\left(\frac{\ln t - \mu}{\sigma}\right) \quad (6)$$

onde Φ é a função de distribuição acumulada da distribuição normal.

A função de taxa de falha é dada por:

$$\lambda(t) = \frac{1}{\sigma t} e^{\frac{(\ln t - \mu)^2}{2\sigma^2}} \quad (7)$$

Embora a distribuição lognormal seja amplamente utilizada em diversas aplicações industriais, ela apresenta limitações em cenários onde o risco de falha aumenta significativamente

com o tempo, como em sistemas com taxa crescente de falha. Nesses casos, pode não refletir com precisão o comportamento real do sistema. No entanto, para análises em que falhas em tempos mais longos não são o foco principal, a distribuição lognormal é uma escolha eficaz para modelagem (Capelo, 2022). Essa distribuição é especialmente útil na análise de falhas por desgaste progressivo de componentes, como rolamentos e motores, e em produtos sujeitos ao envelhecimento, onde a probabilidade de falha aumenta com o tempo devido a influências ambientais e ao uso contínuo (Pham, 2022).

2.2.2 Distribuição Weibull

A distribuição Weibull é uma ferramenta fundamental na análise de confiabilidade, amplamente utilizada para modelar o tempo até a falha de componentes e sistemas. Sua flexibilidade permite descrever diferentes padrões de falha, tornando-a ideal para diversos contextos industriais. Segundo Colosimo e Giolo (2024), essa distribuição se adapta a cenários em que as taxas de falha podem ser constantes, decrescentes ou crescentes, dependendo do valor do parâmetro de forma β . A função de densidade de probabilidade (PDF) da distribuição Weibull é expressa por:

$$f(t) = \frac{\beta}{\eta} \left(\frac{t}{\eta} \right)^{\beta-1} e^{-\left(\frac{t}{\eta}\right)^\beta}, \quad t \geq 0 \quad (8)$$

O parâmetro β é crucial, pois determina o padrão da taxa de falha:

- $\beta < 1$ indica uma taxa de falha decrescente.
- $\beta = 1$ indica uma taxa de falha constante.
- $\beta > 1$ indica uma taxa de falha crescente.

A função de sobrevivência, que indica a probabilidade de um sistema operar sem falhas até um tempo t , é expressa por:

$$S(t) = e^{-\left(\frac{t}{\eta}\right)^\beta} \quad (9)$$

A taxa de falha é dada por:

$$\lambda(t) = \frac{\beta}{\eta} \left(\frac{t}{\eta} \right)^{\beta-1} \quad (10)$$

Uma característica distintiva da distribuição Weibull, conforme ressaltado por Capelo (2022), é que ela é o único modelo que pode ser utilizado tanto na análise de riscos proporcionais quanto no tempo de vida acelerado. Entretanto, é importante considerar as limitações da distribuição Weibull: em cenários onde a taxa de falha apresenta comportamento multimodal, essa distribuição não é recomendada.

Em resumo, a distribuição Weibull se destaca na análise de confiabilidade por sua flexibilidade e capacidade de modelar diversos padrões de falha. Essa versatilidade a torna uma escolha popular e quase sempre única em contextos industriais.

2.3 Aprendizagem de Máquina

O aprendizado de máquina (AM) é uma subárea da inteligência artificial que permite que algoritmos aprendam com os dados e se ajustem para obter o melhor modelo (Faceli *et al.*, 2021), em vez de seguir regras fixas pré-definidas. Essa abordagem torna o AM uma ferramenta poderosa para tarefas preditivas e descritivas, onde padrões complexos nos dados podem prever falhas.

2.3.1 Tipos de Aprendizagem

Os algoritmos de aprendizagem de máquina segundo Murphy (2012) são classificados em três tipos principais.

- **Aprendizado supervisionado:** Modelos são treinados com dados rotulados, onde cada entrada possui uma saída associada. O objetivo é aprender a mapear entradas para saídas e, assim, realizar previsões em novos conjuntos de dados. **Exemplo:** Reconhecimento de imagens – treinar um modelo com fotos classificadas como "gato" ou "não gato" para identificar gatos em novas fotos.
- **Aprendizado não supervisionado:** Utiliza dados sem rótulos para identificar padrões ou estruturas inerentes. **Exemplo:** Agrupamento de clientes – analisar dados de compras para segmentar consumidores com comportamentos semelhantes, como "compradores de eletrônicos" ou "compradores de livros".
- **Aprendizado por reforço:** Envolve um agente que aprende a tomar decisões interagindo com um ambiente, recebendo recompensas ou penalidades como *feedback*. **Exemplo:** Robótica – ensinar um robô a andar, concedendo recompensas quando mantém o equilíbrio e penalidades quando cai.

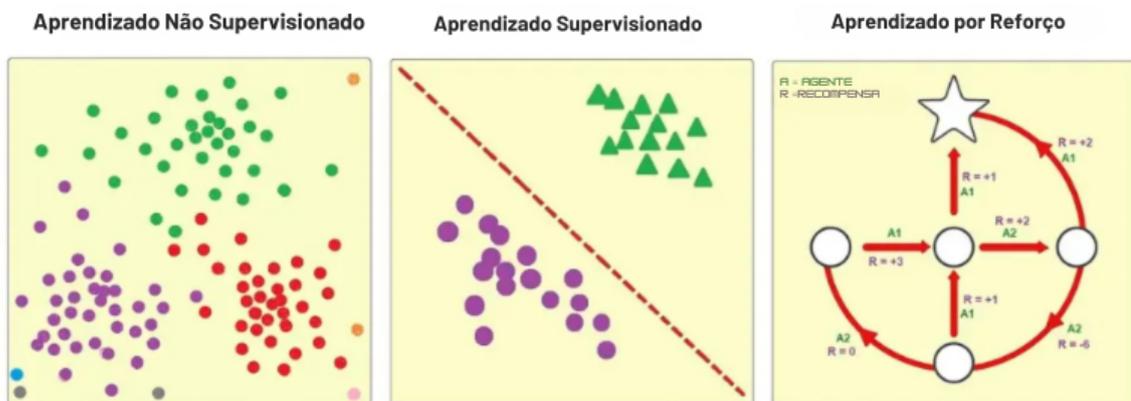


Figura 1 – Tipos de aprendizado.

Fonte: Adaptado de Arya (2024).

2.3.2 Modelos de Aprendizado de Máquina Aplicados à Análise de Confiabilidade

Os modelos de aprendizado de máquina empregados em análises de confiabilidade e sobrevivência são, em sua maioria, modelos de regressão com aprendizado supervisionado.

Uma revisão da literatura mostra que métodos baseados em árvores de decisão, especialmente *Random Survival Forest* (RSF) e *Gradient Boosting for Survival* (GBS), têm se destacado pela simplicidade e eficiência, como evidenciado por Capelo (2022) e Costa *et al.* (2022). Esses modelos são amplamente utilizados devido à sua excelente capacidade de ajuste aos dados, além de sua aptidão para lidar com censura, conforme destacado por Oliveira *et al.* (2019) e Sonabend e Bender (2025).

Outros métodos de aprendizado de máquina, como *Support Vector Machines* (SVM) e redes neurais, também são aplicados na análise de confiabilidade. No entanto, trabalhos como os de Rezaeizadeh e Mastellone (2024), Afshari *et al.* (2022) e Fouodo *et al.* (2018) mostram que o SVM, embora eficaz em problemas de classificação (como prever se um equipamento falhará ou não), apresenta limitações no contexto de regressão, pois tende a produzir estimativas irrealisticamente elevadas, dificultando a interpretação dos resultados.

Por outro lado, modelos baseados em redes neurais, como demonstrado nos trabalhos de Bae *et al.* (2023) e Moradi, Habibirad e Panahi (2024), apresentam ótimo desempenho em análises de sobrevivência. No entanto, essa abordagem tem um alto custo computacional e exige grandes volumes de dados para um treinamento eficaz.

Neste trabalho, optou-se por focar nos métodos RSF e GBS, que se mostraram mais adequados para lidar com censura e oferecem um bom equilíbrio entre simplicidade e desempenho, conforme evidenciado pelas referências revisadas.

2.3.3 Métodos baseados em Árvores

As árvores de decisão são modelos de aprendizado de máquina que realizam previsões ao dividir o espaço de características em subconjuntos hierárquicos, de forma recursiva, até atingir um critério de parada (Faceli *et al.*, 2021). Em problemas de regressão, o objetivo é prever valores contínuos e não categorias discretas. Para isso, as divisões em cada nó da árvore são baseadas na redução da variância ou no erro quadrático médio (MSE), que medem a dispersão dos valores da variável alvo nos subconjuntos resultantes (Breiman, 2017).

A estrutura básica de uma árvore de decisão é composta por:

- **Nós:** Representam testes realizados em atributos (características) dos dados.
- **Ramos:** Indicam os possíveis resultados desses testes.
- **Folhas:** Representam as decisões ou previsões finais do modelo.

O funcionamento do algoritmo segue um processo recursivo:

1. Inicia-se com um nó raiz, que contém todo o conjunto de dados.

Árvore de Decisão Simples

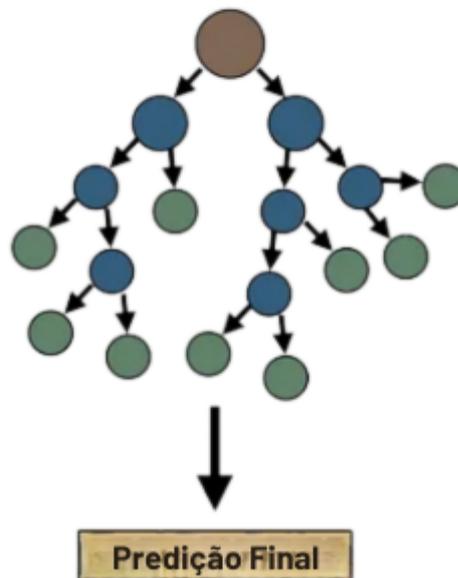


Figura 2 – Representação de uma árvore de decisão.

Fonte: Adaptado de Talebi (2023).

2. Um atributo é selecionado para dividir os dados em subconjuntos, com base em um critério de divisão.
3. Esse processo de divisão é repetido para cada subconjunto gerado, criando novos nós e ramos, até que um critério de parada seja atingido.
4. Ao final, as folhas da árvore fornecem as previsões

Os critérios de parada determinam quando o algoritmo deve interromper a divisão dos nós, evitando que a árvore cresça indefinidamente ou se torne excessivamente complexa. Os principais critérios de paradas são:

- **Número mínimo de amostras em um nó:** Se o número de amostras em um nó for menor que um limite pré-definido, a divisão para.
- **Profundidade máxima da árvore:** Limita o número de níveis da árvore para evitar sobreajuste.
- **Homogeneidade das amostras:** Se todas as amostras em um nó pertencem à mesma classe (em classificação) ou têm valores muito próximos (em regressão), a divisão é interrompida.
- **Ausência de atributos:** Se não houver mais atributos disponíveis para dividir, o processo termina.

Os critérios de divisão avaliam qual atributo é o mais adequado para separar os dados em um dado nó, buscando reduzir a variabilidade (em regressão). Em problemas de regressão, o critério mais comum é a redução da variância, que mede a dispersão dos valores alvo em um nó. A fórmula da variância é:

$$\text{Variância} = \frac{1}{N} \sum_{i=1}^N (y_i - \bar{y})^2 \quad (11)$$

onde:

- N é o número de amostras no nó,
- y_i são os valores alvo individuais,
- \bar{y} é a média dos valores alvo no nó.

Embora sejam interpretáveis, as árvores de decisão podem sofrer overfitting, especialmente quando são complexas (Faceli *et al.*, 2021).

2.3.4 *Random Survival Forest (RSF)*

A *Random Survival Forest* (RSF) é uma adaptação do *Random Forest* (RF) proposta por Ishwaran *et al.* (2008) que adapta o modelo para análise de sobrevivência, visando modelar o tempo até a ocorrência de um evento (por exemplo, falha de um equipamento ou morte de um paciente), considerando dados censurados (quando o evento de interesse não foi observado para algumas amostras). O RSF é uma abordagem não paramétrica que estima a função de sobrevivência e a função de risco cumulativa, sendo capaz de capturar relações não lineares e complexas entre variáveis preditivas e tempos de evento.

A estrutura básica de uma RSF é composta por um conjunto de árvores de decisão adaptadas para sobrevivência, onde cada árvore é construída independentemente. Os principais componentes são:

- **Nós:** Representam testes realizados em atributos (características) dos dados, com divisões baseadas na maximização da separação das curvas de sobrevivência.
- **Ramos:** Indicam os possíveis resultados desses testes, direcionando as observações para subgrupos mais homogêneos em termos de sobrevivência.
- **Folhas:** Contêm estimativas da função de sobrevivência para as observações que chegam àquela folha, geralmente calculadas pelo estimador de Kaplan-Meier.

O funcionamento do algoritmo RSF segue um processo recursivo e *ensemble*:

1. Para cada árvore, uma amostra *bootstrap* é gerada a partir do conjunto de dados original, selecionando observações com reposição, conforme exemplificado na Figura 3.

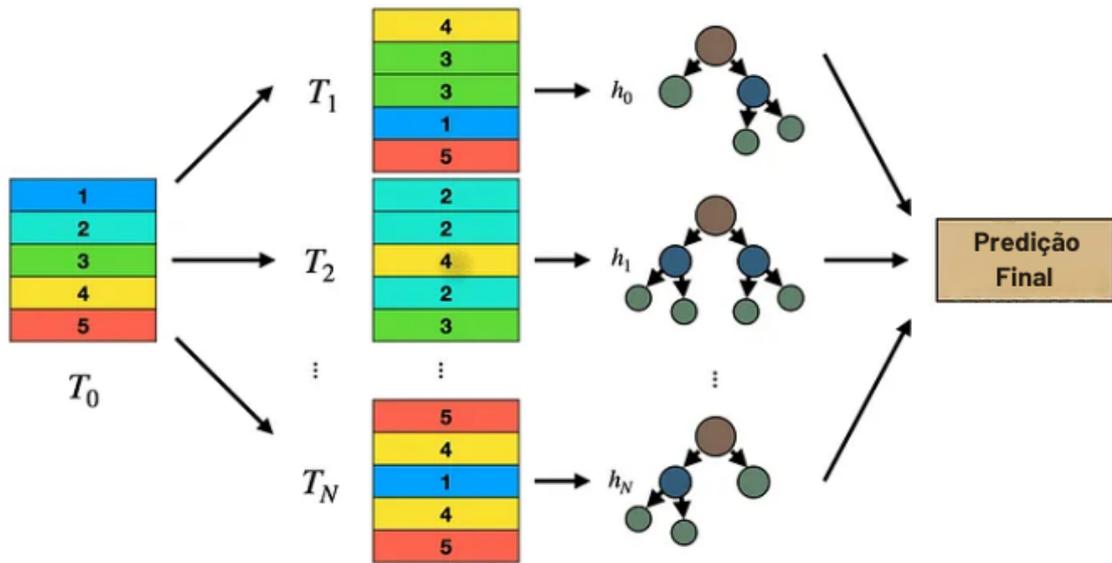


Figura 3 – Ilustração de um algoritmo de Random Survival Forest

Fonte: Adaptado de Talebi (2023).

2. Em cada nó da árvore, um subconjunto aleatório de variáveis é selecionado, e a melhor divisão é determinada usando a estatística log-rank, que maximiza a diferença nas taxas de sobrevivência entre os grupos resultantes.
3. Esse processo de divisão é repetido recursivamente para cada subconjunto até que um critério de parada seja atingido.
4. Nas folhas, a função de sobrevivência é estimada para as observações presentes.
5. A estimativa final para uma nova observação é obtida pela média das estimativas de todas as árvores.

Os critérios de parada determinam quando o algoritmo deve interromper a divisão dos nós, evitando que as árvores se tornem excessivamente complexas. Os principais critérios são:

- **Número mínimo de amostras em um nó:** A divisão para se o nó tiver menos observações que um limite pré-definido
- **Profundidade máxima da árvore:** Limita o número de níveis para evitar sobreajuste.
- **Homogeneidade das amostras:** Se as observações em um nó apresentam curvas de sobrevivência muito similares, a divisão é interrompida.

O critério de divisão no RSF é baseado na estatística log-rank, que avalia a separação das curvas de sobrevivência entre os grupos formados pela divisão. Esse critério maximiza a diferença

nas taxas de risco entre os grupos resultantes da divisão, permitindo que a árvore capture as variações na sobrevivência associadas às características. A fórmula da estatística log-rank é:

$$\text{log-rank} = \frac{(\sum_{i=1}^k O_i - E_i)^2}{\sum_{i=1}^k \text{Var}(O_i - E_i)} \quad (12)$$

onde:

- k é o número de tempos de evento distintos,
- O_i é o número observado de eventos em um dos grupos no tempo (i),
- E_i é o número esperado de eventos, assumindo igualdade de sobrevivência.

Após a construção das árvores, a **função de risco cumulativa** $H(t|X)$ para um novo ponto de dados X é estimada como a média das funções de risco cumulativas das árvores individuais:

$$\hat{H}(t|X) = \frac{1}{B} \sum_{b=1}^B \hat{H}_b(t|X) \quad (13)$$

onde $\hat{H}_b(t|X)$ é a estimativa da função de risco da b -ésima árvore para o ponto X . A **função de sobrevivência** $S(t|X)$ é então obtida pela relação

$$\hat{S}(t|X) = \exp(-\hat{H}(t|X)) \quad (14)$$

2.3.5 Gradient Boosting Survival (GBS)

O *Gradient Boosting Survival* (GBS) é uma adaptação do *Gradient Boosting Machine* (GBM) desenvolvida especificamente para a análise de sobrevivência. Ele é projetado para modelar o tempo até a ocorrência de um evento de interesse, como a falha de um equipamento ou a morte de um paciente, considerando dados censurados — ou seja, situações em que o evento não é observado para todas as amostras. O GBS constrói um modelo preditivo combinando múltiplas árvores de decisão de maneira sequencial, onde cada árvore subsequente corrige os erros das anteriores, resultando em uma estimativa refinada da função de risco ou da função de sobrevivência (Friedman, 2001).

A base do GBS é um conjunto de árvores de decisão treinadas iterativamente. Cada árvore é ajustada aos resíduos (erros) do modelo atual, e o modelo final é obtido como a soma ponderada de todas as árvores. O algoritmo segue um processo estruturado:

1. **Inicialização:** O modelo começa com uma previsão inicial constante, $\hat{F}_0(x)$, que por *default* é a média dos valores de saída em regressão.
2. **Cálculo dos resíduos:** Em cada iteração m , os resíduos $r_i^{(m)}$ são calculados com base no gradiente negativo da função de perda.

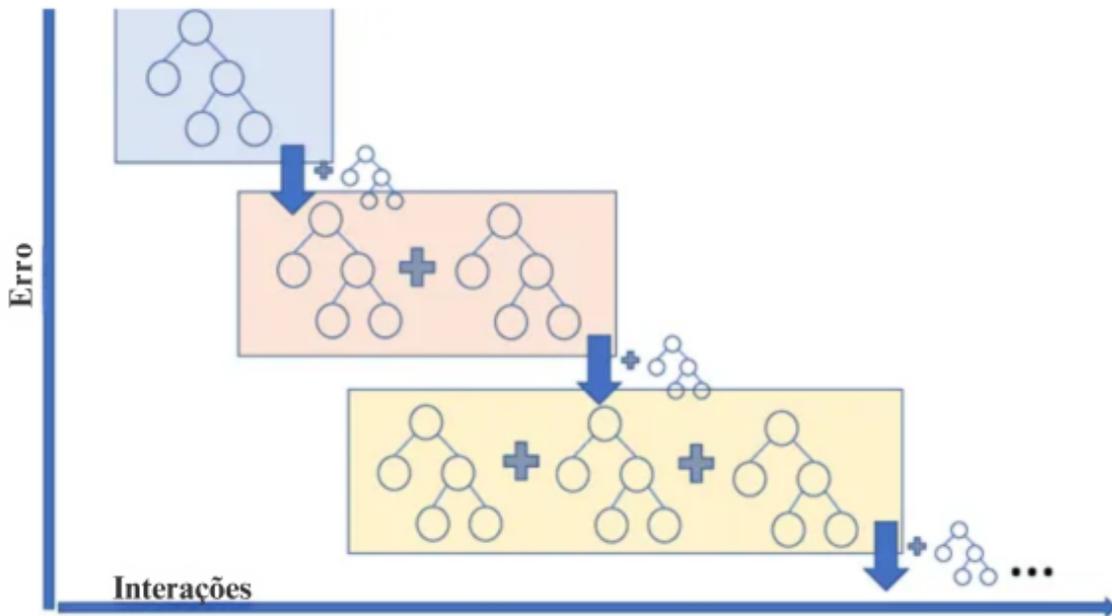


Figura 4 – Ilustração de um algoritmo de Gradient Boosting Machine

Fonte: Adaptado de Choudhury (2020).

3. **Ajuste de uma nova árvore:** Uma nova árvore de decisão $\hat{h}_m(x)$ é ajustada aos resíduos $r_i^{(m)}$ para corrigir os erros do modelo atual.
4. **Atualização do modelo:** O modelo é atualizado somando a previsão da nova árvore, ponderada por uma taxa de aprendizado η , que controla a contribuição de cada árvore.
5. **Iteração:** Esse processo é repetido por M iterações, até que o modelo final seja obtido.

O GBS utiliza como critérios de parada principais:

- **Número máximo de iterações M :** Define o limite de árvores adicionadas ao modelo.
- **Tamanho mínimo das folhas:** Restringe a complexidade das árvores individuais, evitando divisões excessivas.
- **Melhoria mínima na função de perda:** O processo é interrompido se a adição de uma nova árvore não resultar em uma melhora significativa no desempenho.

A função de perda no GBS é adaptada para dados de sobrevivência e frequentemente baseada na função de risco parcial de Cox, dada por:

$$L(\beta) = - \sum_{i:\delta_i=1} \left(\beta^\top x_i - \log \sum_{j:t_j \geq t_i} \exp(\beta^\top x_j) \right) \quad (15)$$

- onde δ_i é um indicador que vale 1 se o evento foi observado e 0 se foi censurado,

- x_i representa as características da observação i ,
- t_i é o tempo de sobrevivência associado.

No GBS, as funções de risco e sobrevivência são estimadas indiretamente por meio de um modelo aditivo baseado em árvores de decisão. O modelo final, denotado $\hat{F}(x)$, é construído como a soma ponderada das previsões de cada árvore:

$$\hat{F}(x) = \sum_{m=1}^M \eta \hat{h}_m(x) \quad (16)$$

- onde $\hat{h}_m(x)$ é a previsão da m -ésima árvore,
- η é a taxa de aprendizado.

Em algumas implementações, $\hat{F}(x)$ representa uma aproximação da **função de risco cumulativa** $H(t|x)$, que é definida como a integral da função de risco $h(t|x)$ ao longo do tempo:

$$H(t|x) = \int_0^t h(u|x) du \quad (17)$$

A **função de sobrevivência** $S(t|x)$, que indica a probabilidade de que o evento não tenha ocorrido até o tempo t , é calculada a partir da relação:

$$\hat{S}(t|x) = \exp(-\hat{H}(t|x)) \quad (18)$$

Vale destacar que a maneira exata como $\hat{H}(t|x)$ e $\hat{S}(t|x)$ são derivadas pode depender da implementação específica do GBS. Algumas abordagens podem optar por estimar diretamente a função de sobrevivência ou usar formulações alternativas para a função de perda, ajustando-se às necessidades do problema (Sonabend e Bender, 2025).

2.3.6 Comparação entre RSF e GBS

Com base no que foi apresentado nas subseções 2.3.4 e 2.3.5, foi elaborada a tabela 1, que resume as diferenças entre os dois métodos.

Tabela 1 – Comparação entre GBS e RSF.

| Característica | GBS | RSF |
|---------------------------|---|---|
| Método de <i>Ensemble</i> | <i>Boosting</i> (treinamento sequencial, corrigindo erros anteriores) | <i>Bagging</i> (amostragem <i>bootstrap</i> para gerar árvores independentes) |
| Crescimento das Árvores | Árvores treinadas sequencialmente | Árvores treinadas paralelamente |

Quadro 0 – Comparação entre GBS e RSF.

(conclusão)

| Característica | GBS | RSF |
|------------------------------|--|--|
| Combinação das Árvores | Soma ponderada das previsões das árvores | Média das árvores (votação ou combinação da função de risco) |
| Função de Perda | Função de perda adaptada para sobrevivência | Baseada na função de sobrevivência |
| Performance com Dados Ruídos | Pode ser mais sensível ao <i>overfitting</i> se não for bem ajustado | Mais robusto ao ruído, menos propenso a <i>overfitting</i> |
| Objetivo Principal | Reduzir viés | Reduzir a variância |
| Adequação | Melhor para problemas onde há complexidade na relação de risco | Funciona bem com grandes conjuntos de dados |

Fontes: Elaborado pelo Autor.

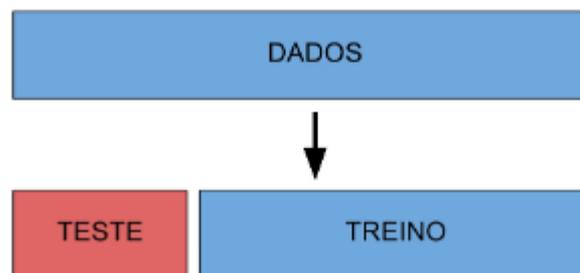
2.4 Validação de Modelos de Aprendizado de Máquina

A validação de modelos de aprendizado de máquina é essencial para garantir que o modelo generalize bem para dados não vistos, evitando problemas como *overfitting*. Neste contexto, exploramos duas técnicas amplamente utilizadas: o método *hold-out* e a validação cruzada *K-Fold*.

2.4.1 Hold-out

O método *hold-out* (Figura 5) é uma técnica de avaliação de modelos de aprendizado de máquina que consiste na divisão de um conjunto de dados em dois subconjuntos: treinamento e teste (Veloso, 2022).

Figura 5 – Hold-out



Fonte: Elaborado pelo Autor

- **Treinamento:** Usado para ajustar os parâmetros do modelo, permitindo que ele aprenda padrões a partir dos dados.
- **Teste:** Reservado para avaliar o desempenho do modelo em novos dados, garantindo que ele generalize bem para amostras não vistas.

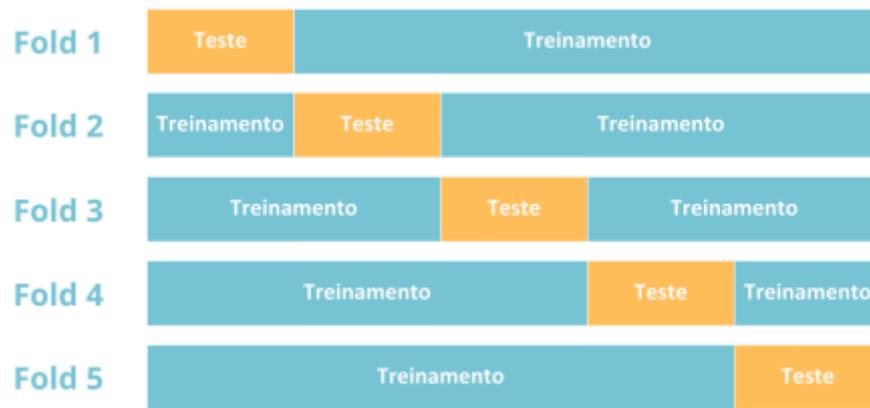
Segundo Hastie, Tibshirani e Friedman (2009), a proporção treino-teste deve considerar o tamanho e a variabilidade dos dados:

- **Grandes conjuntos** (> 10000 amostras): 80% treino e 20% teste.
- **Pequenos conjuntos** (< 1000 amostras): 60%-70% treino e 30%-40% teste.
- **Alta variabilidade**: até 30% dos dados para teste.

2.4.2 Validação Cruzada

A validação cruzada K-Fold (Figura 6) é uma técnica para avaliar a generalização de modelos de aprendizado de máquina (Simionato, 2022).

Figura 6 – K-Fold



Fonte: Elaborado pelo Autor

O procedimento segue as seguintes etapas:

1. **Divisão dos Dados:** O conjunto de dados é dividido em K subconjuntos (*folds*) de tamanho semelhante.
2. **Treinamento e Teste:** Em cada iteração, um *fold* é usado para teste, enquanto os $K - 1$ restantes treinam o modelo. Esse processo se repete K vezes, garantindo que cada *fold* seja usado como teste uma vez.
3. **Avaliação:** A média das métricas obtidas ao longo das iterações fornece uma estimativa do desempenho do modelo.

Segundo Kohavi (1995), os valores mais comuns para K são:

- $K = 10$: Recomendado para conjuntos pequenos (< 1000 amostras), pois maximiza o uso dos dados para treinamento (90% dos dados por iteração), reduzindo o viés.
- $K = 5$: Preferível para conjuntos grandes (> 10000 amostras), pois reduz o custo computacional sem comprometer significativamente a precisão.

- *Leave-One-Out Cross-Validation (LOOCV)* ($K = N$): Neste caso, K é igual ao número total de observações N , ou seja, cada instância do conjunto de dados é usada uma única vez como teste, enquanto as $N - 1$ restantes são utilizadas para treinamento. Esse método é indicado para conjuntos muito pequenos (< 100 amostras), pois maximiza o uso dos dados para treinamento, mas pode ser computacionalmente custoso para bases maiores, já que o modelo precisa ser treinado N vezes.

Além de apresentar valores comuns, Kohavi (1995) também sugere critérios para a escolha do K ideal, considerando:

- **Tamanho do conjunto:** Conjuntos menores se beneficiam de K maiores (ex.: 10), enquanto conjuntos grandes podem usar $K = 5$ para eficiência computacional.
- **Recursos computacionais:** Quanto maior K , maior o tempo de processamento. Se o tempo for um fator crítico, $K = 5$ é uma opção mais viável.
- **Viés vs. Variância:** K muito pequeno pode levar a alta variância, enquanto K muito grande (ex.: LOOCV) pode resultar em baixa variância, mas alto custo computacional. $K = 10$ é um bom equilíbrio.

Para a maioria dos casos, $K = 10$ é recomendado por fornecer estimativas robustas e amplamente validadas na literatura.

2.5 Estatísticas de Desempenho

A avaliação do desempenho de modelos preditivos é crucial para garantir a eficácia das previsões realizadas. Duas métricas amplamente utilizadas para essa finalidade são Índice Integrado de Brier (IBS) e o C-index.

2.5.1 Índice Integrado de Brier (IBS)

O *Índice Integrado de Brier* (IBS) é uma métrica utilizada para avaliar a qualidade das previsões probabilísticas ao longo do tempo em modelos de sobrevivência (Kvamme e Borgan, 2019). Ele representa a média do erro quadrático médio das previsões de sobrevivência em múltiplos instantes temporais, fornecendo uma medida global do desempenho preditivo do modelo.

Para compreender o IBS, primeiro define-se o *Brier Score* (BS), que mede o erro quadrático médio entre a probabilidade predita de sobrevivência e o desfecho observado em um tempo específico t :

$$BS(t) = \frac{1}{N} \sum_{i=1}^N (\hat{S}(t|x_i) - \delta_i(t))^2 \quad (19)$$

Onde:

- N é o número de observações;

- $\hat{S}(t|x_i)$ é a probabilidade predita de sobrevivência para o indivíduo i no tempo t ;
- $\delta_i(t)$ é um indicador que assume valor 1 se o evento ocorreu antes ou até o tempo t , e 0 caso contrário.

A partir do *Brier Score*, define-se o *Índice Integrado de Brier* como:

$$IBS = \frac{1}{T} \int_0^T BS(t) dt \quad (20)$$

Onde:

- T é o tempo máximo de observação;
- $BS(t)$ é o *Brier Score* calculado no tempo t .

O IBS varia de 0 a 1, sendo que valores mais próximos de 0 indicam um modelo com melhor desempenho preditivo. Como ele integra o erro ao longo do tempo, é particularmente útil para comparar modelos em cenários onde o risco de falha muda ao longo do período de análise (Kvamme e Borgan, 2019).

2.5.2 C-index

O C-index é amplamente utilizado para avaliar a habilidade de um modelo de sobrevivência em discriminar entre indivíduos com diferentes riscos (Uno *et al.*, 2011). Ele mede o grau de concordância entre as predições do modelo e os tempos de falha observados, sendo particularmente útil para verificar a capacidade do modelo de prever corretamente a ordem dos eventos.

Matematicamente, o C-index é definido como a proporção de pares de indivíduos cuja ordem de predição de risco está de acordo com a ordem observada dos tempos de falha. A fórmula pode ser representada como:

$$C = \frac{\sum \mathbb{I}(\hat{S}(t_i) < \hat{S}(t_j)) \mathbb{I}(t_i < t_j)}{\sum \mathbb{I}(t_i < t_j)} \quad (21)$$

Onde:

- $\mathbb{I}(\cdot)$ é a função indicadora, que retorna 1 se a condição for verdadeira e 0 caso contrário;
- $\hat{S}(t_i)$ e $\hat{S}(t_j)$ são as probabilidades de sobrevivência preditas para os indivíduos i e j , respectivamente;
- t_i e t_j são os tempos de falha observados.

O C-index varia de 0,5 a 1, onde 0,5 indica uma performance equivalente ao acaso, e 1 representa uma perfeita concordância entre as predições e os tempos de falha observados. Valores acima de 0,7 são geralmente considerados indicativos de boa discriminação por parte do modelo (Uno *et al.*, 2011).

2.5.3 Comparação entre C-Index e Integrated Brier Score

Com base no que foi apresentado nas subseções 2.5.1 e 2.5.2, foi elaborada a Tabela 2, que resume as principais diferenças entre os dois métodos.

Tabela 2 – Comparação entre Integrated Brier Score (IBS) e C-index.

| Característica | Integrated Brier Score (IBS) | C-index |
|-----------------------------|--|--|
| Objetivo | Avaliar a calibração do modelo ao longo do tempo | Avaliar a capacidade do modelo em discriminar entre indivíduos com diferentes riscos |
| Métrica | Média do Brier Score ao longo de um intervalo de tempo | Proporção de pares em que a ordem de risco predita corresponde à ordem dos eventos |
| Intervalo de valores | 0 (melhor) a 1 (pior) | 0,5 (aleatório) a 1 (perfeito) |
| Tipo de avaliação | Mede a acurácia das previsões probabilísticas em múltiplos tempos | Mede a capacidade do modelo de ordenar corretamente os riscos individuais |
| Uso em censura | Funciona com dados censurados, utilizando estimadores de Kaplan-Meier para compensar censura | Funciona com dados censurados, adaptando a comparação entre pares |
| Desvantagens | Pode ser sensível à escolha do intervalo de integração e ao desbalanceamento de eventos | Pode não captar bem pequenas diferenças no risco entre indivíduos |
| Interpretação | Quanto menor o valor, melhor a calibração do modelo | Quanto mais próximo de 1, melhor a discriminação do modelo |
| Aplicação típica | Avaliação geral da qualidade da previsão de sobrevivência ao longo do tempo | Comparação da capacidade discriminativa entre diferentes modelos de sobrevivência |

Fontes: Elaborado pelo Autor.

3 MATERIAIS E MÉTODOS

Nesta seção, é apresentado o desenvolvimento do projeto elaborado, discorrendo sobre os passos adotados para sua elaboração.

3.1 Base de Dados

A base de dados utilizada neste estudo foi extraída do sistema de gestão empresarial SAP, especificamente do módulo PM (*Plant Maintenance*), utilizado pela indústria calçadista onde o estudo de caso foi realizado (localizada na região metropolitana de João Pessoa, Paraíba). Os registros de manutenção, abrangendo o período de 1º de janeiro de 2023 a 31 de dezembro de 2024, são alimentados continuamente pela equipe de manutenção através de dispositivos móveis (*SAP Mobile*) e, posteriormente, revisados pela equipe de PCM (Planejamento e Controle da Manutenção), garantindo informações atualizadas e consistentes sobre as intervenções.

Considerando que o objetivo central da análise de sobrevivência é modelar o tempo até eventos que cessam a funcionalidade do equipamento, foram utilizados os registros de manutenção corretiva emergencial, pois estes representam as falhas não planejadas que efetivamente interrompem a operação das máquinas injetoras. Os dados brutos correspondentes a essas ocorrências foram exportados do SAP PM no formato de planilha eletrônica (.xlsx).

Inicialmente, a base de dados bruta exportada continha um número maior de atributos e amostras (originalmente 4.843 amostras com 23 atributos cada), que foram subsequentemente processados e filtrados conforme descrito nas seções seguintes. A análise final considerou a totalidade das 189 máquinas injetoras da planta industrial.

3.1.1 Seleção das Variáveis

A base inicial continha 23 atributos. No entanto, após uma análise criteriosa, alinhada com as diretrizes internas de planejamento de manutenção da empresa, apenas cinco atributos foram selecionados. Essa seleção priorizou variáveis de relevância direta para a modelagem de falhas e o planejamento de manutenções, refletindo os fatores considerados essenciais pela empresa para o acompanhamento e análise do desempenho das máquinas injetoras.

Tabela 3 – Descrição das Variáveis Selecionadas.

| Variável | Descrição | Categoria | Tipo |
|------------|---|--|--------|
| Processo | Representa o processo produtivo no qual a máquina está alocada. | Injeção Termoplástica Injeção Expansiva | Object |
| Fabricante | Representa o fabricante de cada máquina. | Tien Kang Golden Eagle KCKLA King Steel | Object |

Quadro 0 – Descrição das Variáveis Seleccionadas.

(conclusão)

| Variável | Descrição | Categoria | Tipo |
|----------|---|-----------------------|---------|
| TAG | Código numérico que identifica o equipamento individualmente. | Valor numérico | Object |
| TTR | Duração das intervenções de manutenção. | Valor numérico(Horas) | Float64 |
| TTF | Intervalo de tempo entre falhas consecutivas de um equipamento. | Valor numérico(Horas) | Float64 |

Fontes: Elaborado pelo Autor.

As variáveis TTR e TTF não estavam presentes na base original e foram derivadas a partir dos registros de data e horário das ordens de manutenção. O cálculo dessas métricas foi feito via Script, realizado da seguinte forma:

- **Tempo até a Falha (TTF):** Representa o tempo contínuo em que o equipamento operou sem falhas entre o término do reparo da falha anterior e o início da falha subsequente. Este intervalo, fundamental para a modelagem de sobrevivência, foi calculado como a diferença entre o instante de início da falha atual ($t_{\text{início, falha atual}}$) e o instante de término do reparo da falha imediatamente anterior ($t_{\text{término, reparo anterior}}$), conforme a Equação 22:

$$\text{TTF} = t_{\text{início, falha atual}} - t_{\text{término, reparo anterior}} \quad (22)$$

Assim, o TTF representa estritamente o tempo de operação contínua (uptime) entre o fim de um reparo e o início da falha seguinte, excluindo-se, portanto, os Tempos Para Reparo (TTR) tanto da manutenção anterior quanto da intervenção subsequente a este período de funcionamento.

- **Tempo de Reparo (TTR):** Corresponde à duração da parada para a intervenção corretiva, ou seja, o tempo de indisponibilidade do equipamento devido à manutenção. Foi obtido pela diferença entre o horário de término do reparo ($t_{\text{término, reparo}}$) e o horário de início do mesmo reparo ($t_{\text{início, reparo}}$) registrados na respectiva ordem de manutenção (Equação 23):

$$\text{TTR} = t_{\text{término, reparo}} - t_{\text{início, reparo}} \quad (23)$$

3.1.2 Caracterização dos Equipamentos

O parque fabril analisado neste estudo compreende 189 máquinas injetoras, distribuídas em dois processos produtivos principais: Injeção Termoplástica (158 unidades), responsável pela produção de componentes como forquilhas para suprimento da própria fábrica e de outras

unidades da companhia, e Injeção Expansiva (31 unidades), voltada à fabricação de solados. Quatro diferentes fabricantes compõem esta população de equipamentos, cujas características são detalhadas a seguir.

O processo de Injeção Expansiva emprega máquinas KCLKA (17 unidades) e King Steel (14 unidades). O modelo KCLKA EK3-6E2Eva representa aquisições recentes, com menos de 3 anos de operação. Já o modelo King Steel ZT-KS-910UE4 possui um tempo de serviço consideravelmente maior, superior a 10 anos, similar às unidades Tien Kang. Para ambos os fabricantes deste processo, fontes comuns de parada reportadas incluem problemas relacionados ao sistema de injeção e ao controle de aquecimento.

A Figura 7 ilustra os modelos de injetoras de cada fabricante mencionado, com imagens baseadas nos manuais técnicos.



(a) Tien Kang TK-103TC-2S-B.



(b) Golden Eagle GEK160w/s.



(c) KCLKA EK3-6E2Eva.



(d) King Steel ZT-KS-910UE4.

Figura 7 – Ilustração dos modelos de máquinas injetoras por fabricante (imagens baseadas nos manuais).

A caracterização desta população heterogênea de equipamentos — abrangendo diferentes modelos, fabricantes, tempos de operação e perfis gerais de falha observados — estabelece o

contexto dos ativos industriais cuja confiabilidade foi modelada e analisada neste estudo.

3.2 Pré-carregamento e Tratamento dos Dados

Os dados foram inicialmente processados no *Google Sheets*, pois os arquivos importados estavam no formato *Excel*. Nesse ambiente, aplicaram-se filtros, ajustes e reorganizações para a obtenção da base tratada. Após esse tratamento, os dados foram exportados para *Python*, onde foram realizadas análises exploratórias e o desenvolvimento dos modelos. Registros com valores ausentes em qualquer uma das cinco colunas selecionadas foram excluídos, a fim de garantir a consistência dos dados e evitar distorções na análise. Em modelos de sobrevivência, a imputação pode introduzir vieses na estimativa da confiabilidade e da função de risco, especialmente quando os dados não estão ausentes de forma completamente aleatória (Klein e Moeschberger, 2003).

Ordens de manutenção duplicadas, geradas por erros no registro, foram unificadas, com informações como datas, horários e tempos de reparo consolidadas para evitar que o modelo interpretasse tais duplicatas como eventos independentes. Foram identificadas também ordens de manutenção sobrepostas, nas quais registros menores estavam contidos em ordens maiores do mesmo equipamento; nesses casos, manteve-se apenas a ordem mais abrangente para garantir a consistência dos dados. Além disso, ordens de manutenção com tempo de reparo inferior a 15 minutos foram removidas da base, seguindo a política de *Chokotei* baseada na Manutenção Produtiva Total (TPM), que desconsidera paradas curtas por sua baixa relevância operacional.

Após o pré-tratamento no *Google Sheets*, os dados foram importados via arquivo CSV para o *Google Colab*, uma plataforma baseada na nuvem que oferece um ambiente interativo de programação em *Python* por meio da interface *Jupyter Notebook*. A biblioteca *Pandas*, empregada na manipulação dos dados, foi utilizada para a criação de um *dataframe*, possibilitando sua manipulação. Em seguida, realizou-se uma visualização inicial dos dados para verificar possíveis erros na estrutura e nos tipos das variáveis, conforme exibido na Figura 8a. Constatou-se que as variáveis *TTR* e *TTF* apresentavam o tipo incorreto (*object*), necessitando ser convertidas para o tipo *float64* e ter a vírgula substituída pelo ponto como separador decimal; os dados ajustados podem ser visualizados na Figura 8b.

| | Processo | TAG | Fabricante | TTR | TTF |
|------|-----------------------|----------|--------------|------|---------|
| 0 | INJECAO EXPANSIVO | 41018062 | KING STEEL | 1,16 | 151,874 |
| 1 | INJECAO EXPANSIVO | 41018062 | KING STEEL | 0,79 | 92,562 |
| 2 | INJECAO EXPANSIVO | 41018062 | KING STEEL | 0,70 | 7,067 |
| 3 | INJECAO EXPANSIVO | 41018062 | KING STEEL | 0,91 | 207,846 |
| 4 | INJECAO EXPANSIVO | 41018062 | KING STEEL | 0,46 | 96,259 |
| ... | ... | ... | ... | ... | ... |
| 2819 | INJECAO TERMOPLASTICO | 41016101 | GOLDEN EAGLE | 0,43 | 45,238 |
| 2820 | INJECAO TERMOPLASTICO | 41016101 | GOLDEN EAGLE | 0,82 | 3,318 |
| 2821 | INJECAO TERMOPLASTICO | 41016101 | GOLDEN EAGLE | 0,77 | 14,507 |
| 2822 | INJECAO TERMOPLASTICO | 41016101 | GOLDEN EAGLE | 0,84 | 36,329 |
| 2823 | INJECAO TERMOPLASTICO | 41016101 | GOLDEN EAGLE | 0,83 | 79,243 |

[2824 rows x 5 columns]

```

Processo      object
TAG           int64
Fabricante    object
TTR           object
TTF           object
dtype: object

```

| | Processo | TAG | Fabricante | TTR | TTF |
|------|-----------------------|----------|--------------|------|---------|
| 0 | INJECAO EXPANSIVO | 41018062 | KING STEEL | 1.16 | 151.874 |
| 1 | INJECAO EXPANSIVO | 41018062 | KING STEEL | 0.79 | 92.562 |
| 2 | INJECAO EXPANSIVO | 41018062 | KING STEEL | 0.70 | 7.067 |
| 3 | INJECAO EXPANSIVO | 41018062 | KING STEEL | 0.91 | 207.846 |
| 4 | INJECAO EXPANSIVO | 41018062 | KING STEEL | 0.46 | 96.259 |
| ... | ... | ... | ... | ... | ... |
| 2819 | INJECAO TERMOPLASTICO | 41016101 | GOLDEN EAGLE | 0.43 | 45.238 |
| 2820 | INJECAO TERMOPLASTICO | 41016101 | GOLDEN EAGLE | 0.82 | 3.318 |
| 2821 | INJECAO TERMOPLASTICO | 41016101 | GOLDEN EAGLE | 0.77 | 14.507 |
| 2822 | INJECAO TERMOPLASTICO | 41016101 | GOLDEN EAGLE | 0.84 | 36.329 |
| 2823 | INJECAO TERMOPLASTICO | 41016101 | GOLDEN EAGLE | 0.83 | 79.243 |

[2824 rows x 5 columns]

```

Processo      object
TAG           object
Fabricante    object
TTR           float64
TTF           float64
dtype: object

```

(a) Visualização dos dados

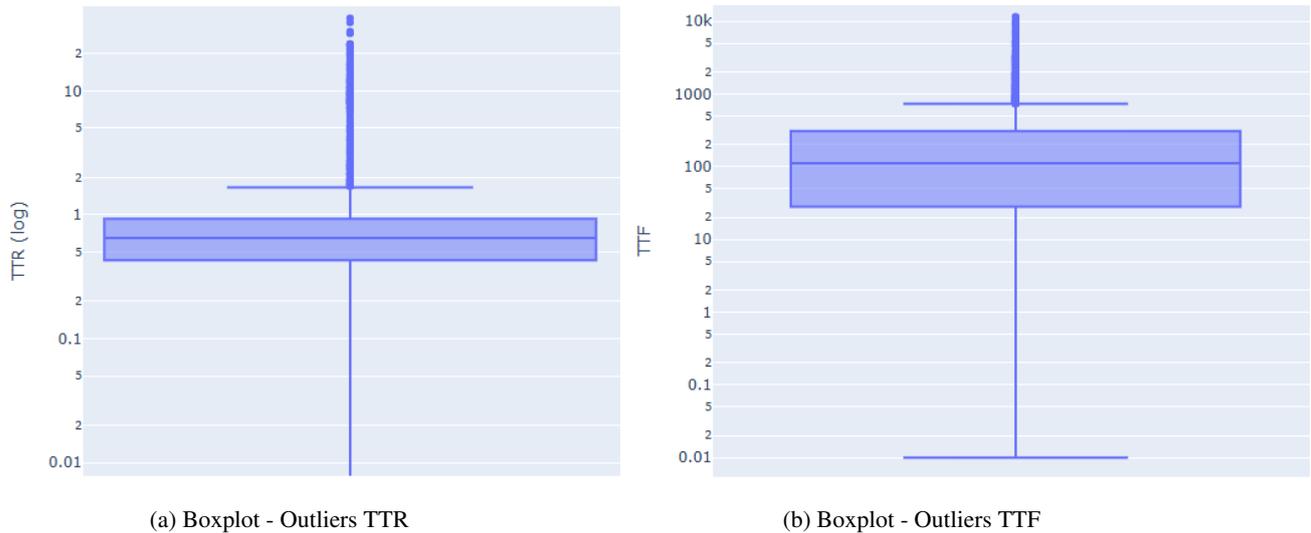
(b) Visualização dos dados corrigida

Figura 8 – Pré e Visualização dos dados

Fonte: Elaborado pelo Autor

Posteriormente, efetuou-se o tratamento de *outliers* para as variáveis TTR e TTF utilizando o método do *Intervalo Interquartil* (IQR), conforme proposto por Hall, Rogers e Pregibon (1982). Os *outliers* foram eliminados da base de dados, pois sua presença poderia distorcer as estimativas dos parâmetros em modelos de sobrevivência e afetar significativamente as conclusões da análise.

Figura 9 – Outliers



Fonte: Elaboração própria.

Após o tratamento dos dados, a amostra resultante passou a contar com 5 atributos e 2824 amostras.

3.3 Modelos

Os modelos desenvolvidos incluem a distribuição Weibull com covariáveis, a distribuição Lognormal com covariáveis, além dos modelos *Random Survival Forest* (RSF) e *Gradient Boosting Survival* (GBS). O código foi implementado e executado na plataforma *Google Colab*. É importante destacar que todas as falhas foram observadas, o que implica que os modelos não apresentam censura ($\text{Event} = 1$). Para a divisão dos dados em treino e teste, bem como para a validação cruzada, os parâmetros foram selecionados conforme explicado na subseções 2.4.1 e 2.4.2.

3.3.1 Modelagem Paramétrica

Os modelos baseados nas distribuições Weibull e Lognormal foram implementados utilizando a biblioteca *lifelines* e o método *Accelerated Failure Time* (AFT), por meio das classes *WeibullAFTFitter* e *LogNormalAFTFitter*. As covariáveis consideradas foram Processo, Fabricante, TAG e TTR, enquanto a variável de interesse foi o TTF (Tempo até a Falha). Os parâmetros de distribuição e a influência das variáveis foram estimados por meio do método *summary* da biblioteca *lifelines*. Para avaliar o desempenho, utilizaram-se as métricas *Integrated Brier Score* (IBS) e C-index. O conjunto de dados foi dividido em 70% para treinamento e 30% para teste, com *k-fold* ($K=5$) para garantir melhor generalização dos modelos.

3.3.2 Modelagem de Aprendizado de Máquina

Os modelos RSF e GBS foram desenvolvidos com a biblioteca `scikit-survival`, utilizando as mesmas covariáveis e variável de interesse da modelagem paramétrica. As variáveis categóricas foram transformadas em vetores binários pelo método `one-hot encoding`. O conjunto de dados foi dividido em 70% para treinamento e 30% para teste, com *K-fold* ($K=10$) para melhorar a generalização dos modelos.

Os modelos foram ajustados utilizando `RandomSurvivalForest` para o RSF e `GradientBoostingSurvivalAnalysis` para o GBS. A otimização dos hiperparâmetros foi realizada por meio do método `RandomizedSearchCV`, com `n_iter = 20`, escolhido para reduzir o custo computacional do modelo.

Além disso, foi realizada uma análise da importância das variáveis por permutação, utilizando o método `permutation_importance` da biblioteca `scikit-survival`. As métricas de avaliação empregadas foram o C-index e o IBS.

A Tabela 4 apresenta os parâmetros de busca utilizados para cada modelo, enquanto a Tabela 5 apresenta os valores obtidos após a otimização realizada.

Tabela 4 – Hiperparâmetros Utilizados na Busca para Modelos RSF e GBS

(a) – Modelo RSF

| Hiperparâmetro | Descrição | Intervalo | Variação |
|-------------------|--|----------------------|---------------|
| n_estimators | Número de árvores no modelo (<i>Random Forest</i>) | 1 a 1100 | 1 |
| max_depth | Profundidade máxima de cada árvore | 1 a 110 | 1 |
| min_samples_split | Número mínimo de amostras necessárias para dividir | 1 a 31 | 1 |
| min_samples_leaf | Número mínimo de amostras em uma folha | 1 a 31 | 1 |
| max_features | Número máximo de características a considerar | 'sqrt', 'log2', None | Valores fixos |

(b) – Modelo GBS

| Hiperparâmetro | Descrição | Intervalo | Variação |
|-------------------|--|----------------------|---------------|
| n_estimators | Número de árvores no modelo | 1 a 1100 | 1 |
| learning_rate | Taxa de aprendizado | 0.01 a 0.1 | 100 pontos |
| max_depth | Profundidade máxima de cada árvore | 1 a 110 | 1 |
| min_samples_split | Número mínimo de amostras necessárias para dividir | 1 a 31 | 1 |
| min_samples_leaf | Número mínimo de amostras em uma folha | 1 a 31 | 1 |
| max_features | Número máximo de características a considerar | 'sqrt', 'log2', None | Valores fixos |

Fonte:Elaborado pelo Autor.

Tabela 5 – Hiperparâmetros Otimizados - RSF e GBS

(a) – Modelo RSF

| Hiperparâmetro | Valor |
|-------------------|-------|
| n_estimators | 498 |
| max_depth | 65 |
| min_samples_split | 25 |
| min_samples_leaf | 28 |
| max_features | sqrt |

(b) – Modelo GBS

| Hiperparâmetro | Valor |
|-------------------|-------|
| n_estimators | 657 |
| learning_rate | 0.028 |
| max_depth | 93 |
| min_samples_split | 2 |
| min_samples_leaf | 29 |
| max_features | sqrt |

Fonte: Elaborado pelo Autor.

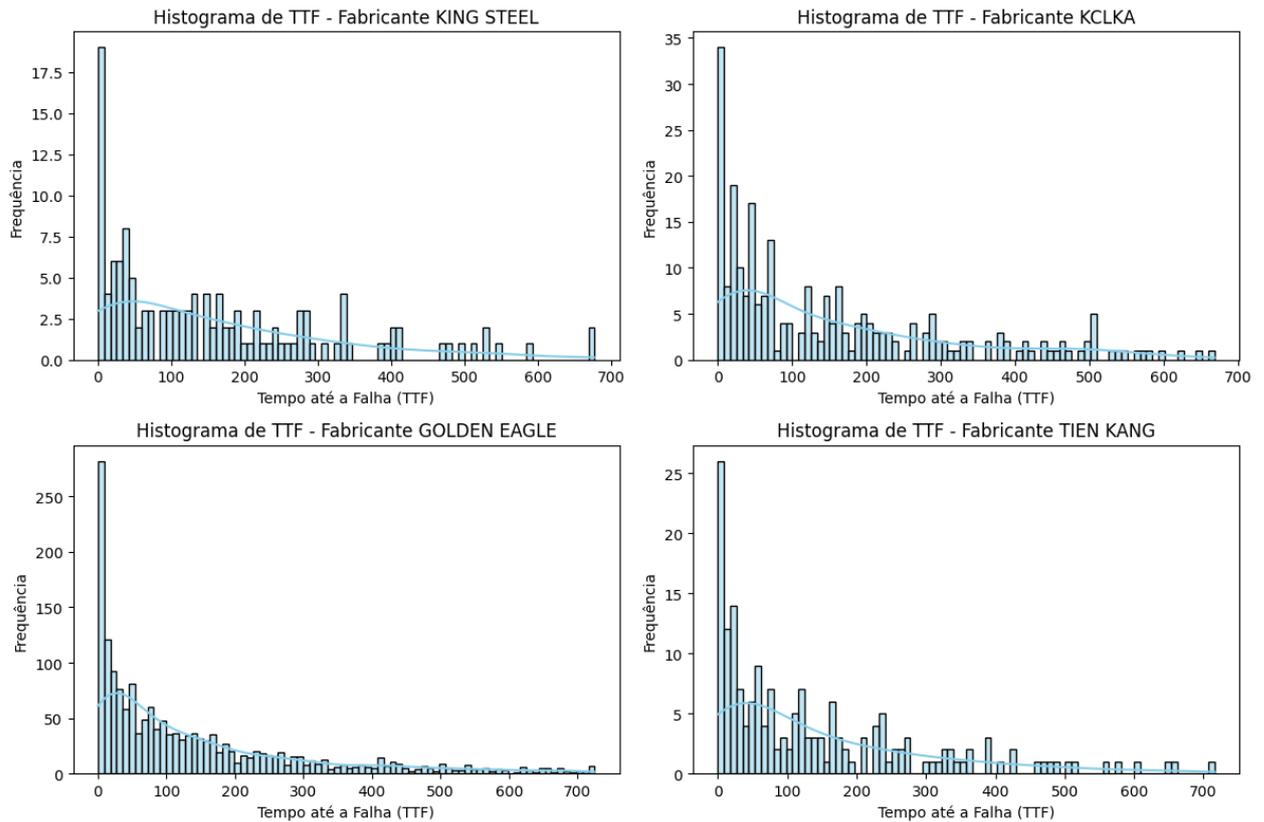
4 RESULTADOS E DISCUSSÕES

Nesta seção, são apresentados os resultados obtidos pelos modelos gerados.

4.1 Análise do Comportamento do Tempo de Falha

Nesta seção, analisamos o TTF (tempo até a falha) em relação às variáveis predictoras: Processo, Fabricante e TTR.

Figura 10 – Histograma de TTF por fabricante



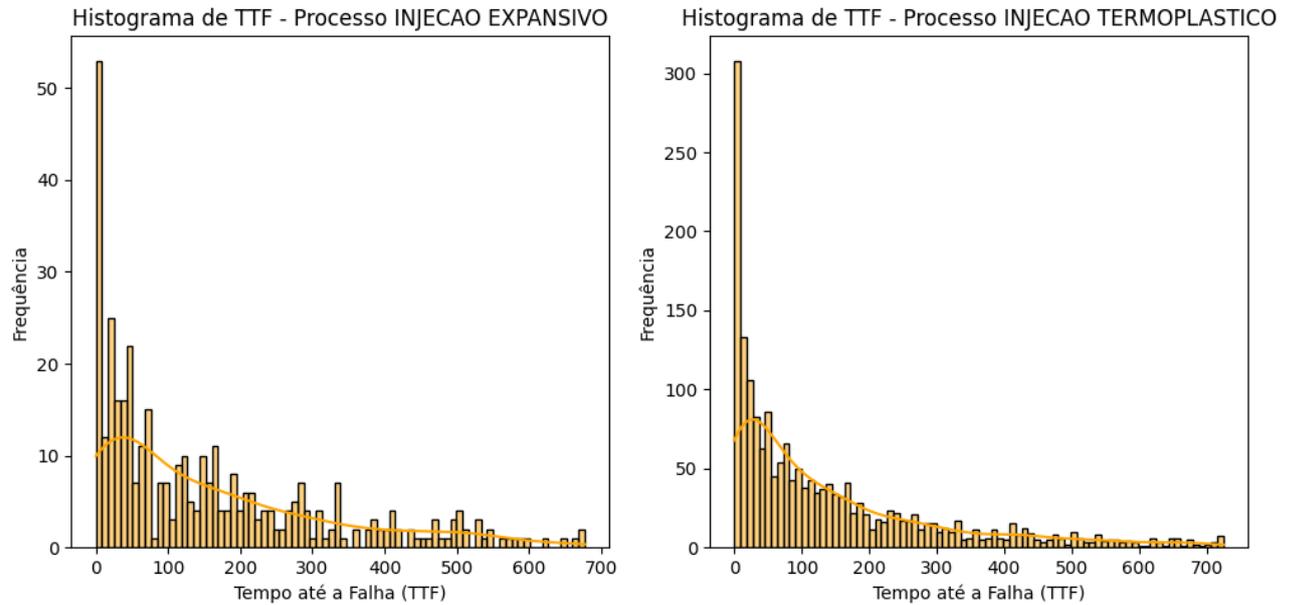
Fonte: Elaborado pelo Autor

Na Figura 10, observa-se uma assimetria positiva, indicando alta incidência de falhas iniciais, seguidas por uma cauda à direita. Todos os fabricantes apresentam falhas precoces, mas com variações na intensidade: GOLDEN EAGLE e TIEN KANG exibem maior concentração no início, enquanto KING STEEL e KCLKA têm distribuições menos concentradas e falhas mais distribuídas ao longo do tempo.

Na Figura 11, ambos os processos também exibem forte assimetria positiva. INJEÇÃO TERMOPLÁSTICO apresenta um pico acentuado no início, indicando falhas quase imediatas, enquanto INJEÇÃO EXPANSIVO tem uma distribuição mais suavizada, com maior proporção de unidades superando os estágios iniciais.

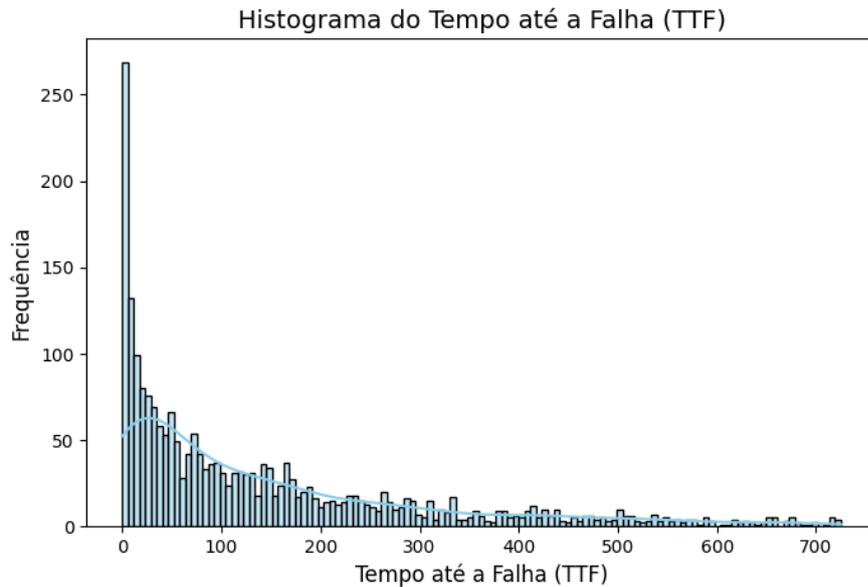
O histograma geral (Figura 12) destaca a alta incidência de falhas precoces — um fenômeno de “mortalidade infantil” — evidenciado pela rápida queda na taxa de falhas ao longo do tempo, em concordância com os padrões observados nos fabricantes e processos.

Figura 11 – Histograma de TTF por processo



Fonte: Elaborado pelo Autor

Figura 12 – Histograma de TTF Geral

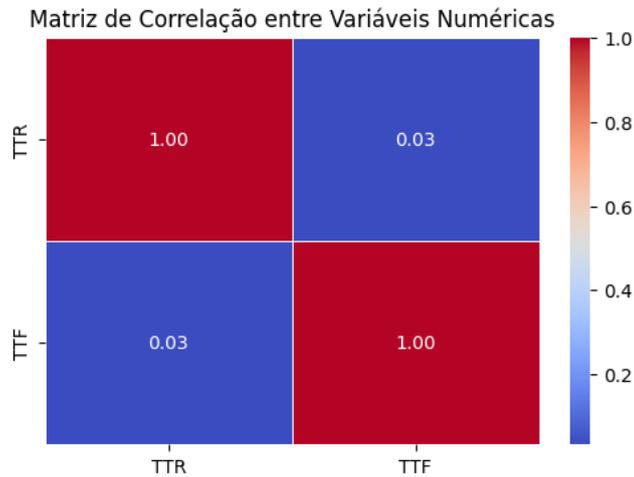


Fonte: Elaborado pelo Autor

Em síntese, os dados indicam alta mortalidade infantil, reforçando sua adequação para análise de sobrevivência. Essas características devem ser consideradas na modelagem para capturar as diferenças significativas no tempo até a falha entre os grupos.

A Figura 13 exibe a matriz de correlação, na qual o coeficiente entre TTR e TTF é 0.03. Esse valor, próximo de zero, indica uma correlação linear desprezível entre as variáveis, sugerindo que variações em TTR não impactam diretamente TTF de forma proporcional. Embora não descarte possíveis relações não lineares ou condicionais, a correlação de Pearson confirma a ausência de dependência linear significativa entre essas variáveis.

Figura 13 – Matriz de Correlação TTR-TTF



Fonte: Elaborado pelo Autor

4.2 Resultado dos Modelos Paramétricos

Esta seção avalia o desempenho dos modelos AFT com distribuições Weibull e Lognormal, servindo como benchmark para comparação com abordagens subsequentes de Aprendizado de Máquina.

Tabela 6 – Desempenho dos Modelos Weibull e Lognormal

| (a) Modelo Weibull | | | (b) Modelo Lognormal | | |
|--------------------|--------|-------|----------------------|--------|-------|
| Métrica | Treino | Teste | Métrica | Treino | Teste |
| C-index | 0,64 | 0,64 | C-index | 0,63 | 0,63 |
| Brier Score | 0,11 | 0,13 | Brier Score | 0,12 | 0,12 |

Fonte: Elaborado pelo Autor.

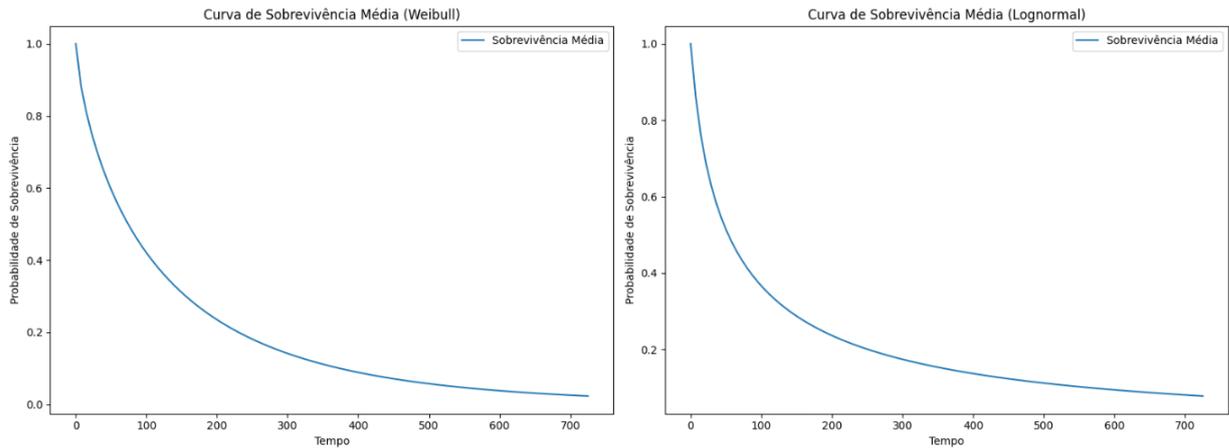
Fonte: Elaborado pelo Autor.

Os resultados quantitativos (Tabela 6) indicam desempenho preditivo moderado para ambos os modelos nos dados de teste, com C-index em torno de 0,63-0,64 e IBS entre 0,12-0,13. As performances de Weibull e Lognormal são similares, como reforça a Figura 14, onde suas curvas de sobrevivência médias praticamente se sobrepõem, indicando concordância na tendência geral de sobrevivência.

Um aspecto positivo foi a capacidade dos modelos de quantificar o efeito do processo produtivo, conforme sugerido pela análise visual (Figura 11). A Figura 15 mostra que ambos os modelos, Weibull e Lognormal, diferenciam os grupos, atribuindo menor probabilidade de sobrevivência ao Processo: INJEÇÃO TERMOPLÁSTICO em comparação ao Processo: INJEÇÃO EXPANSIVO.

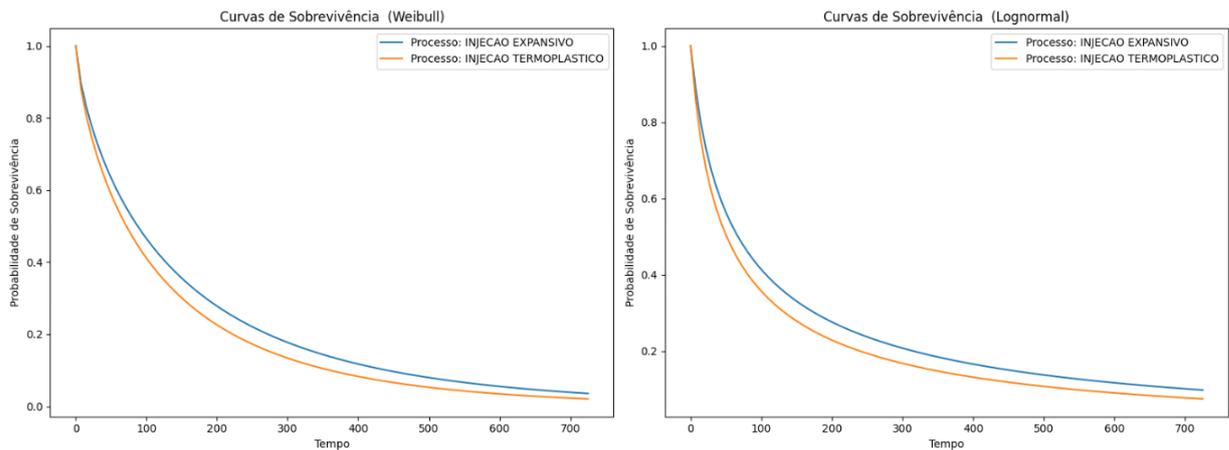
Contudo, uma análise mais detalhada dos sumários de ajuste (Tabela 7 para Weibull e Tabela 8 para Lognormal) revela inconsistências. Observa-se divergência na significância das covariáveis: Processo foi significativo apenas no ajuste Weibull ($p = 0,03$), enquanto TTR apenas no Lognormal ($p = 0,01$). Além disso, a significância de TTR no modelo Lognormal contrasta com sua correlação linear quase nula com TTF ($r = 0,03$), conforme mostrado na

Figura 14 – Curvas de Sobrevivência - Modelos Paramétricos



Fonte: Elaborado pelo Autor

Figura 15 – Curvas de Sobrevivência por Processos - Modelos Paramétricos



Fonte: Elaborado pelo Autor

matriz de correlação (Figura 13). Isso sugere que o efeito capturado pelo modelo AFT é mais complexo do que uma simples associação linear.

A adequação da distribuição Weibull é um ponto crítico neste contexto. O sumário do modelo (Tabela 7) indica um parâmetro de forma estimado ($\beta = 1,35$), o que implicaria uma taxa de falha crescente ao longo do tempo para os equipamentos. No entanto, esse resultado contradiz o padrão visual observado nos histogramas de TTF (seção 4.1), os quais exibem uma alta concentração de falhas em tempos de operação reduzidos (valores baixos de TTF). Essa discrepância entre a taxa de falha crescente sugerida pelo modelo ajustado e a observação de muitas falhas ocorrendo cedo levanta dúvidas sobre a capacidade do modelo Weibull AFT padrão de representar adequadamente a dinâmica real de falhas desses equipamentos, especialmente nos estágios iniciais após um reparo ou início de operação.

Os modelos paramétricos *Weibull AFT* e *Lognormal AFT* apresentaram desempenho global moderado e comparável, sendo eficazes na quantificação do impacto do processo produ-

Tabela 7 – Resultados Completos do Modelo Weibull Ajustado

| Sumário do Modelo | | Outras Estatísticas | | | | |
|--------------------|----------|---------------------------|------------------------|--|--|--|
| Observações | 1579 | AIC | 18594,79 | | | |
| Eventos Observados | 1579 | log-likelihood ratio test | 7,14 (3 df, p = 0,068) | | | |
| Log-Likelihood | -9292,40 | -log2(p) of ll-ratio test | 3,88 | | | |

| Estimativas dos Parâmetros | | | | | | |
|----------------------------|-------|-----------|----------|--------|--------|----------|
| Parâmetro | coef | exp(coef) | se(coef) | z | p | -log2(p) |
| lambda_ | | | | | | |
| Intercept | 4,80 | 121,52 | 269,24 | 0,02 | 0,99 | 0,02 |
| Processo[T.INJECAO...] | -0,22 | 0,81 | 0,10 | -2,18 | 0,03 | 5,08 |
| TAG | 0,00 | 1,00 | 0,00 | 0,00 | 1,00 | 0,00 |
| TTR | 0,14 | 1,15 | 0,11 | 1,33 | 0,18 | 2,44 |
| rho_ | | | | | | |
| Intercept | -0,30 | 0,74 | 0,02 | -14,47 | <0,005 | 155,22 |

Fonte: Elaborado pelo Autor .

Tabela 8 – Resultados Completos do Modelo Lognormal Ajustado

| Sumário do Modelo | | Outras Estatísticas | | | | |
|--------------------|----------|---------------------------|--------------------------|--|--|--|
| Observações | 1579 | AIC | 18977,63 | | | |
| Eventos Observados | 1579 | log-likelihood ratio test | 17,08 (3 df, p = 0,0007) | | | |
| Log-Likelihood | -9483,81 | -log2(p) of ll-ratio test | 10,52 | | | |

| Estimativas dos Parâmetros | | | | | | |
|----------------------------|---------|-----------|----------|-------|--------|----------|
| Parâmetro | coef | exp(coef) | se(coef) | z | p | -log2(p) |
| mu_ | | | | | | |
| Intercept | -890,10 | 0,00 | 363,25 | -2,45 | 0,01 | 6,13 |
| Processo[T.INJECAO...] | -0,18 | 0,84 | 0,13 | -1,33 | 0,18 | 2,44 |
| TAG | 0,00 | 1,00 | 0,00 | 2,46 | 0,01 | 6,18 |
| TTR | 0,38 | 1,47 | 0,14 | 2,64 | 0,01 | 6,93 |
| sigma_ | | | | | | |
| Intercept | 0,60 | 1,83 | 0,02 | 33,98 | <0,005 | 838,31 |

Fonte: Fonte: Elaborado pelo Autor .

tivo. Entretanto, as análises gráficas revelam limitações importantes, como inconsistências na significância de covariáveis e, mais criticamente, inadequação da forma funcional da taxa de falha do modelo Weibull para capturar as falhas precoces observadas.

4.3 Resultado dos Modelos de Aprendizado de Máquina

Esta seção avalia o desempenho dos modelos de Aprendizado de Máquina aplicados à análise de sobrevivência: *Random Survival Forest (RSF)* e *Gradient Boosting Survival (GBS)*. A análise busca compreender sua performance preditiva, o uso das variáveis disponíveis e o

impacto da configuração dos modelos.

Tabela 9 – Desempenho dos Modelos GBS e RSF

| (a) Modelo RSF | | | (b) Modelo GBS | | |
|----------------|--------|-------|----------------|--------|-------|
| Métrica | Treino | Teste | Métrica | Treino | Teste |
| C-index | 0,88 | 0,79 | C-index | 0,90 | 0,82 |
| Brier Score | 0,09 | 0,10 | Brier Score | 0,08 | 0,09 |

Fonte: Elaborado pelo Autor.

A performance quantitativa dos modelos otimizados, medida no conjunto de teste, está resumida na Tabela 9. Comparando as duas abordagens de AM, o modelo GBS apresentou um desempenho superior, alcançando um C-index de 0,82 e um Brier Score de 0,09, enquanto o RSF obteve C-index de 0,79 e Brier Score de 0,10. Ambos os modelos exibiram uma redução de performance entre os conjuntos de treino e teste, indicando algum sobreajuste, que foi controlado através da otimização de hiperparâmetros.

Tabela 10 – Comparativo da Importância das *Features* por Permutação para Modelos RSF e GBS

| (a) Modelo RSF | | | | (b) Modelo GBS | | | |
|----------------|------------|-------------|----------|----------------|------------|-------------|----------|
| Índice | Feature | Importância | Std Dev | Índice | Feature | Importância | Std Dev |
| 2 | TAG | 0,042727 | 0,010567 | 2 | TAG | 0,029503 | 0,014447 |
| 0 | Processo | 0,002216 | 0,002740 | 3 | TTR | 0,010667 | 0,008235 |
| 1 | Fabricante | -0,000209 | 0,001039 | 1 | Fabricante | 0,010649 | 0,002532 |
| 3 | TTR | -0,000869 | 0,005753 | 0 | Processo | 0,009139 | 0,002887 |

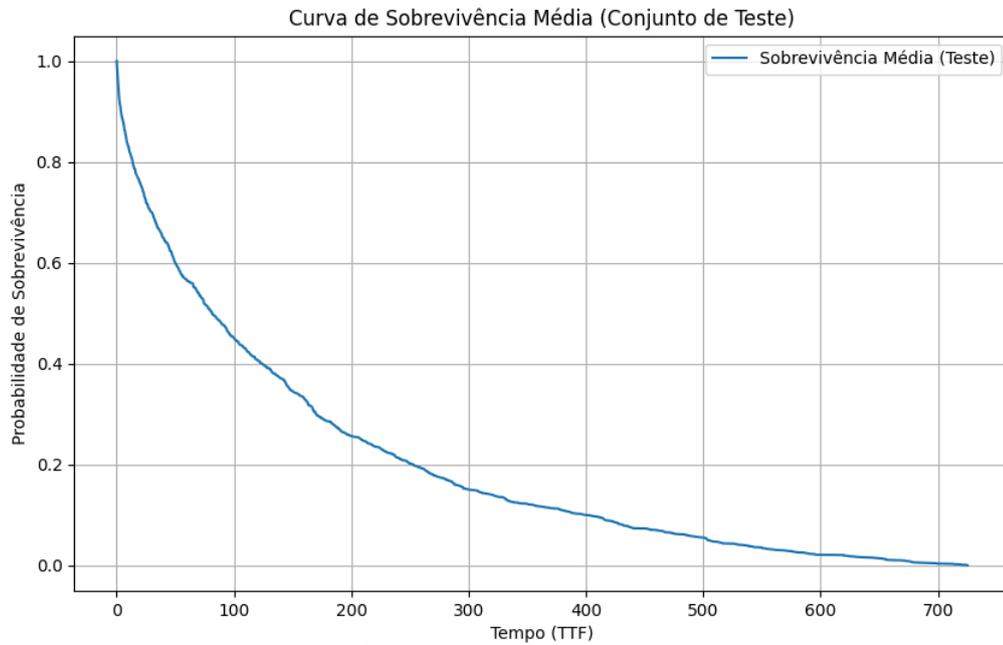
Fonte: Elaborado pelo Autor.

A análise de importância das features por permutação (Tabela 10) revela como os modelos utilizam as variáveis. Um achado consistente é a elevada importância da variável TAG para ambos os modelos, destacando-a como o preditor mais influente. No entanto, observa-se diferenças na utilização das demais variáveis: o RSF atribuiu importância quase nula a TTR e Fabricante, sugerindo que não extraíram valor preditivo significativo. Em contraste, o GBS conferiu importância positiva e relevante a TTR, Fabricante e Processo, indicando uma exploração mais ampla das variáveis. A importância de TTR para o GBS é notável, dado que sua correlação linear com TTF é mínima ($r=0,03$, Figura 13), sugerindo que o modelo captura relações não-lineares ou condicionais.

A influência dos hiperparâmetros, cujo processo de otimização e valores finais ótimos estão detalhados na seção 3.3.2, reflete-se no distinto uso das *features*. No RSF (Tabela 5a), a configuração com `min_samples_split=25` e `min_samples_leaf=28` favoreceu árvores mais regularizadas, o que pode ter limitado a exploração de subgrupos menores e reduzido a importância de TTR e Fabricante. No GBS (Tabela 5b), a combinação de um `learning_rate` baixo (0,028), muitos `n_estimadores`(657), alta profundidade máxima (`max_depth=93`) e um

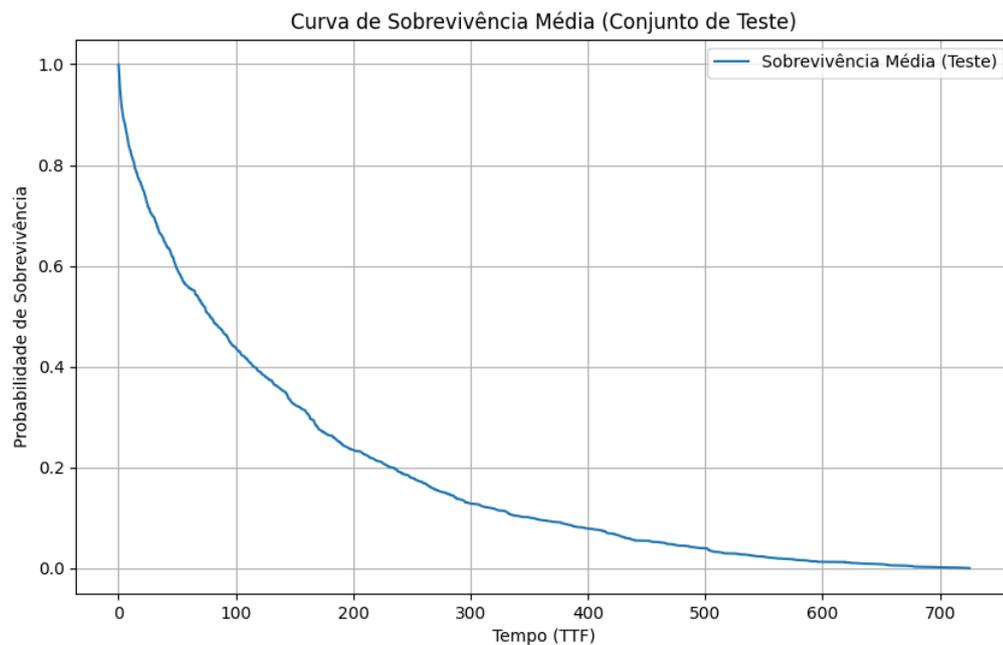
`min_samples_leaf` similarmente restritivo (29), mas com `min_samples_split=2`, permitiu ao modelo construir uma função mais complexa, atribuindo relevância a um conjunto mais amplo de variáveis, incluindo TTR.

Figura 16 – Curva de Sobrevivência - RSF



Fonte: Elaborado pelo Autor

Figura 17 – Curva de Sobrevivência - GBS



Fonte: Elaborado pelo Autor

Do ponto de vista gráfico, as curvas de sobrevivência médias estimadas no conjunto de teste pelos modelos RSF (Figura 16) e GBS (Figura 17) são muito semelhantes e refletem adequadamente o declínio acentuado inicial observado nos histogramas de TTF (seção 4.1).

Ambas as abordagens de AM também foram eficazes em diferenciar os processos produtivos, como mostram as curvas estratificadas (RSF: Figura 18, GBS: Figura 19, que replicam o menor tempo de sobrevivência para o Processo: INJECAO TERMOPLASTICO, um padrão claramente visível nos histogramas comparativos (Figura 11).

Figura 18 – Curvas de Sobrevivência por Processos - RSF

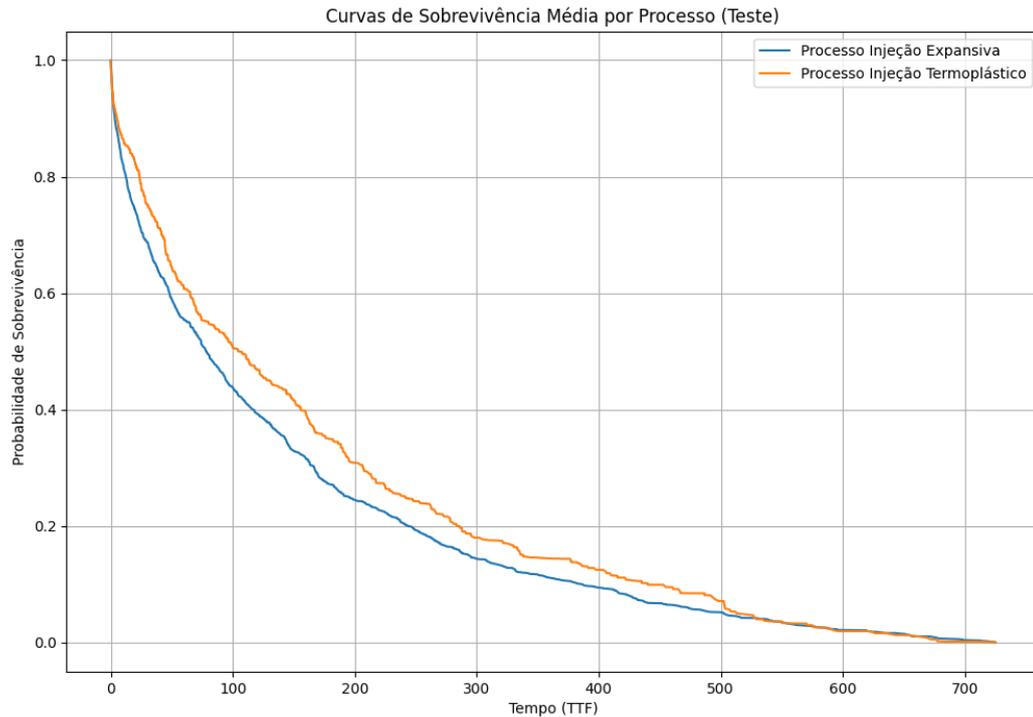
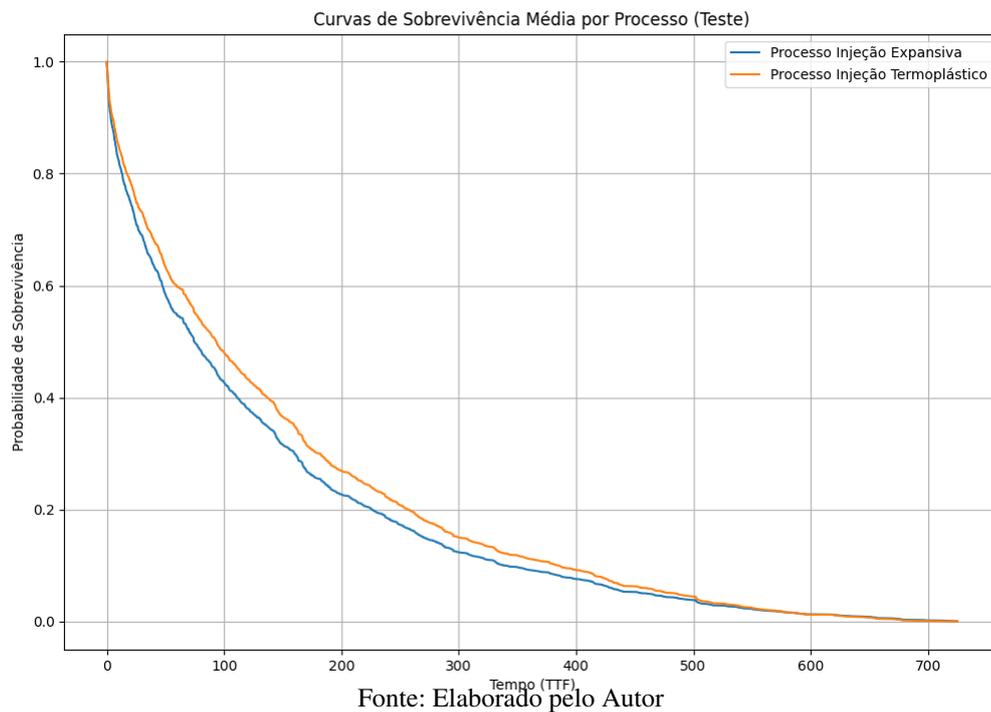


Figura 19 – Curvas de Sobrevivência por Processos- GBS



Em síntese, a avaliação focada nos modelos de Aprendizado de Máquina: RSF e GBS demonstra sua capacidade em modelar os dados de sobrevivência, capturando padrões gerais e específicos (como o efeito do processo) alinhados à análise exploratória inicial. O modelo GBS apresentou as melhores métricas quantitativas. A análise de features, contextualizada pelos hiperparâmetros selecionados na otimização (seção 3.3.2), revelou TAG como variável crítica para ambos, mas com estratégias distintas de utilização das demais variáveis entre os modelos, destacando a capacidade do GBS em atribuir relevância a TTR, Fabricante e Processo neste cenário.

4.4 Análise Comparativa: Modelos Paramétricos vs. Aprendizado de Máquina

Após a avaliação individual dos modelos paramétricos (Weibull *AFT*, Lognormal *AFT*) e das abordagens de Aprendizado de Máquina (*Random Survival Forest* - RSF, *Gradient Boosting Survival* - GBS), realizou-se uma análise comparativa direta para sintetizar os achados, discutir a modelagem das covariáveis e indicar a metodologia mais promissora para prever o tempo de sobrevivência.

A comparação do desempenho preditivo no conjunto de teste, utilizando as métricas C-index e Brier Score (IBS) (Tabelas 6 e 9), favoreceu claramente as abordagens de Aprendizado de Máquina. O modelo GBS apresentou a melhor performance geral (C-index = 0,82; IBS = 0,09), seguido pelo RSF (C-index = 0,79; IBS = 0,10), ambos superando os modelos paramétricos (melhor C-index trad. = 0,64; melhor IBS trad. = 0,12).

Para quantificar essa superioridade, a Tabela 11 apresenta o ganho percentual de desempenho dos modelos de AM em relação à melhor abordagem tradicional para cada métrica.

Tabela 11 – Ganho Percentual de Desempenho dos Modelos de AM sobre Modelos Tradicionais (Conjunto de Teste)

| Modelo | Ganho sobre Tradicional (Melhora no C-index) | Redução sobre Tradicional (Redução no IBS) |
|--------|---|---|
| RSF | 23,44% | 16,67% |
| GBS | 28,13% | 25,00% |

Fonte: Elaborado pelo Autor

Os resultados sumarizados na Tabela 11 evidenciam os ganhos expressivos obtidos com as técnicas de AM. Nota-se que o GBS não apenas alcançou o melhor desempenho absoluto, mas também proporcionou a maior melhoria relativa, com um aumento de 28,13% no poder discriminatório (C-index) e uma redução de 25,00% no erro global (IBS) em comparação aos modelos tradicionais. O RSF também apresentou melhorias relativas significativas, com 23,44% de melhoria no C-index e 16,67% de redução no IBS. Estes ganhos quantitativos estão alinhados com observações na literatura (Graf, Todd e Baksh, 2025; Lu e Guler, 2022) sobre o potencial de modelos de *ensemble* baseados em árvores para superar abordagens clássicas em problemas complexos de sobrevivência, reforçando a adequação do AM para este estudo de caso.

A Figura 20 complementa essa análise quantitativa, apresentando visualmente as curvas

de sobrevivência médias estimadas por todos os modelos no conjunto de teste. A sobreposição das curvas evidencia que, embora todos os modelos capturem o declínio inicial acentuado da probabilidade de sobrevivência, existem diferenças notáveis em suas estimativas. As previsões dos modelos de Aprendizado de Máquina (RSF e GBS) são bastante similares entre si e tendem a estimar uma sobrevivência ligeiramente inferior àquela prevista pelos modelos paramétricos (Weibull AFT e Lognormal AFT), particularmente em tempos mais elevados. Essa divergência visual, onde os modelos de AM atribuem um risco ligeiramente maior ao longo do tempo, corrobora a superioridade métrica (maior C-index, menor IBS) das abordagens de AM verificada na Tabela 11, sugerindo uma representação potencialmente mais realista do processo de falha neste conjunto de dados.

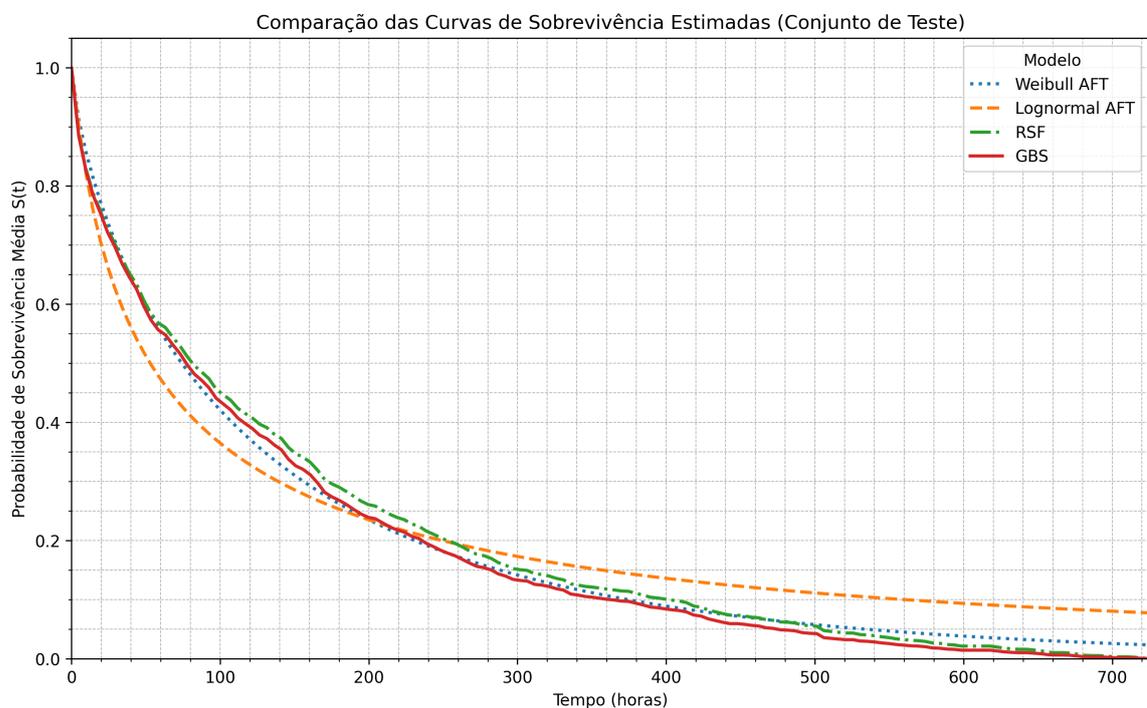


Figura 20 – Comparação das Curvas de Sobrevivência Médias Estimadas pelos Modelos
Fonte: Elaborado pelo Autor

A modelagem das covariáveis também revelou diferenças importantes. Ambos os métodos identificaram o efeito do Processo produtivo, mas os modelos paramétricos mostraram limitações em representar adequadamente o padrão de falhas com alta incidência inicial observado nos histogramas (Figura 12) e inconsistências na significância de outras variáveis (Tabelas 7 e 8). A dificuldade do modelo Weibull AFT em particular ($\beta > 1$, Tabela 7) evidencia a restrição de formas monotônicas para a taxa de falha (Seção 2.2.2), incompatível com a concentração de falhas em tempos menores visualizada nos dados. Os modelos de AM, sendo não paramétricos, adaptaram-se melhor a esses padrões. O GBS, notadamente, utilizou um conjunto mais amplo de covariáveis de forma relevante, incluindo TTR, sugerindo a captura de relações não lineares (Faceli *et al.*, 2021).

A flexibilidade das abordagens de AM foi, portanto, uma vantagem crítica, permitindo

um ajuste mais fiel aos dados sem as fortes premissas distribucionais dos modelos paramétricos (Gogoberidze, 2023; Xue *et al.*, 2025). Essa característica foi crucial para alcançar a superioridade preditiva observada. No entanto, essa vantagem foi acompanhada por maior custo computacional na otimização dos hiperparâmetros (seção 3.3.2) e menor interpretabilidade direta em comparação aos coeficientes dos modelos paramétricos.

Ponderando os fatores analisados, e com base nos ganhos quantitativos expressivos em acurácia preditiva sumarizados na Tabela 11 e na comparação visual apresentada na Figura 20, conclui-se que os modelos de Aprendizado de Máquina, especialmente o GBS, foram significativamente mais precisos na previsão da probabilidade de sobrevivência para as máquinas injetoras neste estudo de caso. Embora os modelos paramétricos tenham servido como um *benchmark* útil, suas limitações foram evidentes. A escolha final em um contexto prático deve balancear a acurácia preditiva, demonstrada pelas métricas e ganhos percentuais, com a necessidade de interpretabilidade e os recursos computacionais disponíveis. Recomenda-se uma investigação adicional sobre a natureza da variável TAG para melhor compreensão dos fatores de risco.

5 CONCLUSÃO

Este Trabalho de Conclusão de Curso realizou uma análise comparativa entre abordagens estatísticas tradicionais (Weibull AFT, Lognormal AFT) e técnicas de Aprendizado de Máquina (RSF, GBS) aplicadas à análise de sobrevivência, focando na estimativa da probabilidade de falha de máquinas injetoras na indústria calçadista. O estudo envolveu análise exploratória dos dados, implementação, otimização e avaliação dos diferentes modelos.

Os resultados quantitativos e a análise das curvas de sobrevivência convergiram para a superioridade preditiva dos modelos de Aprendizado de Máquina, com destaque para o Gradient Boosting Survival (GBS), que apresentou as melhores métricas de desempenho (C-index e IBS). Esta constatação responde à questão central do trabalho e evidencia a vantagem da flexibilidade do AM em capturar os padrões de falha dos dados analisados, superando as limitações das premissas mais rígidas dos modelos paramétricos testados.

A relevância deste estudo reside tanto na contribuição acadêmica, ao apresentar uma comparação empírica em língua portuguesa, quanto na aplicação prática industrial. Os achados sugerem que a adoção de modelos como o GBS pode efetivamente aprimorar a previsão de falhas em injetoras, auxiliando na otimização do planejamento da manutenção preditiva e na consequente redução de custos e paradas não planejadas no setor calçadista.

Reconhecem-se, contudo, limitações inerentes ao estudo. A análise restringiu-se aos dados de uma única planta industrial, limitando a generalização direta dos resultados. Ademais, o foco na precisão preditiva não abrangeu a investigação das causas-raiz das falhas. Importa também considerar que a maior acurácia dos modelos de AM, especialmente GBS, veio acompanhada de maior complexidade computacional e menor interpretabilidade direta, fatores relevantes para a implementação prática.

Como direcionamento para pesquisas futuras, sugere-se a investigação aprofundada das variáveis identificadas como mais relevantes (TAG e TTR), a exploração de outros algoritmos de AM ou modelos semi-paramétricos, e a validação dos achados em outros contextos industriais. A integração dessas abordagens preditivas em sistemas de apoio à decisão para o planejamento da manutenção representa outro caminho promissor.

Conclui-se, portanto, que para o objetivo de maximizar a precisão na previsão da probabilidade de falha das máquinas injetoras neste estudo de caso, as técnicas de Aprendizado de Máquina, notadamente o GBS, demonstraram ser as mais eficazes. Embora os modelos paramétricos ofereçam simplicidade, sua menor capacidade preditiva neste cenário foi superada pela adaptabilidade dos modelos de AM. Apesar da complexidade inerente a estas técnicas mais avançadas, os resultados reforçam seu potencial significativo para aplicações em análise de sobrevivência e confiabilidade na indústria.

REFERÊNCIAS

Abecom. **Paradas não programadas: 07 dicas para reduzir os prejuízos**. 2022. Disponível em: <https://www.abecom.com.br/paradas-nao-programadas/>. Acesso em: 13 abr. 2025.

AFSHARI, Sajad Saraygord *et al.* Machine learning-based methods in structural reliability analysis: a review. **Reliability Engineering & System Safety**, Amsterdam, v. 219, p. 108223, Mar 2022. DOI: <https://doi.org/10.1016/j.ress.2022.108223>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S095183202100639X>. Acesso em: 27 abr. 2025.

ARYA, Nisha. **Types of Machine Learning**. 2024. Disponível em: <https://www.ejable.com/tech-corner/ai-machine-learning-and-deep-learning/types-of-machine-learning/>. Acesso em: 20 mar. 2025.

BAE, Chan Yeong *et al.* A study on survival analysis methods using neural network to prevent cancers. **Cancers**, Basel, v. 15, n. 19, p. 4757, Oct. 2023. DOI: <https://doi.org/10.3390/cancers15194757>. Disponível em: <https://www.mdpi.com/2072-6694/15/19/4757>. Acesso em: 20 mar. 2025.

BARBOSA, Joao Paulo. **Modelagem da confiabilidade de equipamentos por combinações ou extensões de distribuições de Weibull**. Dissertação (Dissertação (Mestrado em Engenharia)) — Universidade Federal do Espírito Santo, Vitória, 2016. Disponível em: https://sappg.ufes.br/tese_drupal//tese_4902_JO%C3%20PAULO%20BARBOSA.pdf. Acesso em: 13 abr. 2025.

BREIMAN, Leo. **Classification and regression trees**. 2. ed. New York: Routledge, 2017.

CAPELO, Pedro Renato Alves. **Florestas aleatórias e árvores de classificação e de regressão na análise de dados censurados**. Dissertação (Dissertação (Mestrado em Estatística Médica)) — Universidade do Minho, Braga, Portugal, 2022. Disponível em: https://repositorium.sdum.uminho.pt/bitstream/1822/80224/1/Pedro%20Renato%20Alves%20Capelo_PG46253_Disserta%C3%A7%C3%A3o.pdf. Acesso em: 21 jan. 2025.

CHENG, Yao; WEI, Yian; LIAO, Haitao. Optimal sampling-based sequential inspection and maintenance plans for a heterogeneous product with competing failure modes. **Reliability Engineering & System Safety**, Amsterdam, v. 218, p. 108181, Feb. 2022. DOI: <https://doi.org/10.1016/j.ress.2021.108181>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0951832021006657>. Acesso em: 21 jan. 2025.

CHOUDHURY, Abhiroop. **What is Gradient Boosting? How is it different from Ada Boost?** [S. l.]: Analytics Vidhya, 2020. Disponível em: <https://medium.com/analytics-vidhya/what-is-gradient-boosting-how-is-it-different-from-ada-boost-2d5ff5767cb2>. Acesso em: 20 mar. 2025.

COLOSIMO, Enrico Antônio; GIOLO, Suely Ruiz. **Análise de sobrevivência aplicada**. 2. ed. São Paulo: Blucher, 2024.

COSTA, João Paulo Vieira *et al.* Lifetime probability of default using survival tree-based models. *In*: ASSOCIAÇÃO PORTUGUESA PARA A INTELIGÊNCIA ARTIFICIAL, 17.,

2022, Lisboa, Portugal. **Iberian Conference on Information Systems and Technologies (CISTI)**. [S. l.]: IEEE, 2022. p. 1–6. DOI: 10.23919/CISTI54924.2022.9820571. Disponível em: <https://doi.org/10.23919/CISTI54924.2022.9820571>. Acesso em: 12 set. 2024.

DHILLON, Balbir S. **Engineering Reliability: New Techniques and Applications**. Boca Raton: CRC Press, 2006.

FACELI, Katti *et al.* **Inteligência Artificial: Uma abordagem de aprendizado de máquina**. 2. ed. Rio de Janeiro: LTC, 2021. E-book. ISBN 9788521637509.

FILHO, Bruno Martins; SISQUINI, Geraldo Rossoni; BARBOSA, João Paulo. Uso da ferramenta análise estatística para tomada de decisão na gestão de manutenção: Estudo de caso compressor de ar. *In: ASSOCIAÇÃO BRASILEIRA DE METALURGIA, MATERIAIS E MINERAÇÃO*, 62., 2023, São Paulo. **Congresso Anual da ABM**. São Paulo: Associação Brasileira de Metalurgia, Materiais e Mineração, 2023. Disponível em: [https://abmproceedings.com.br/ptbr/article/download-pdf/uso-da-ferramenta-anlise-estatistica-para-tomada-decisao-na-gestao-de-manutencao-estudo-de-caso-compressor-de-ar](https://abmproceedings.com.br/ptbr/article/download-pdf/uso-da-ferramenta-analise-estatistica-para-tomada-decisao-na-gestao-de-manutencao-estudo-de-caso-compressor-de-ar). Acesso em: 13 abr. 2025.

FOUODO, Césaire J. K. *et al.* Support vector machines for survival analysis with r. **The R Journal**, Vienna, v. 10, n. 1, p. 453–469, Jul. 2018. ISSN 2073-4859. DOI: 10.32614/RJ-2018-034. Disponível em: <https://journal.r-project.org/archive/2018/RJ-2018-034/index.html>. Acesso em: 10 fev. 2025.

FRIEDMAN, Jerome H. Greedy function approximation: a gradient boosting machine. **Annals of Statistics**, Beachwood, Ohio, v. 29, n. 5, p. 1189–1232, Oct. 2001. DOI: 10.1214/aos/1013203451. Disponível em: <https://projecteuclid.org/euclid.aos/1013203451>. Acesso em: 05 set. 2024.

GOGOBERIDZE, Nodari. **Predictive maintenance in the Internet of Things: survival analysis and deep learning on time series data from a large scale wireless sensor network**. Dissertação (Dissertação (Mestrado)) — Harvard Extension School, Cambridge, MA, 2023. Disponível em: <https://dash.harvard.edu/server/api/core/bitstreams/fe61ab5c-6396-46e5-8a1f-813259a504fb/content>. Acesso em: 13 abr. 2025.

GRAF, Ricarda; TODD, Susan; BAKSH, M. Fazil. **Comparison of the Cox proportional hazards model and Random Survival Forest algorithm for predicting patient-specific survival probabilities in clinical trial data**. 2025. Disponível em: https://www.researchgate.net/publication/388754949_Comparison_of_the_Cox_proportional_hazards_model_and_Random_Survival_Forest_algorithm_for_predicting_patient-specific_survival_probabilities_in_clinical_trial_data. Acesso em: 13 abr. 2025.

HALL, G. J.; ROGERS, W. H.; PREGIBON, D. **Outliers matter in survival analysis**. Santa Monica, CA: [s. n.], 1982. Disponível em: <https://apps.dtic.mil/sti/tr/pdf/ADA119473.pdf>.

HASTIE, Trevor; TIBSHIRANI, Robert; FRIEDMAN, Jerome. **The Elements of Statistical Learning: Data mining, inference, and prediction**. 2. ed. New York: Springer, 2009.

ISHWARAN, Hemant *et al.* Random survival forests. **The Annals of Applied Statistics**, Beachwood, Ohio, v. 2, n. 3, p. 849–874, Sep. 2008. DOI: 10.1214/08-AOAS169. Disponível em: <https://projecteuclid.org/journals/annals-of-applied-statistics/volume-2/issue-3/Random-survival-forests/10.1214/08-AOAS169.full>. Acesso em: 22 nov. 2024.

KARIM, Md. Rezaul; ISLAM, M. Ataharul. **Reliability and Survival Analysis**. Singapura: Springer, 2019. ISBN 978-981-13-9775-2.

KLEIN, John P.; MOESCHBERGER, Melvin L. **Survival Analysis: Techniques for censored and truncated data**. 2. ed. New York: Springer-Verlag, 2003. (Statistics for Biology and Health).

KOHAVI, Ron. A study of cross-validation and bootstrap for accuracy estimation and model selection. *In*: INTERNATIONAL JOINT CONFERENCE ON ARTIFICIAL INTELLIGENCE, 14., 1995, Montreal, Canada. **Proceedings of the International Joint Conference on Artificial Intelligence (IJCAI'95)**. San Francisco, CA: Morgan Kaufmann Publishers, 1995. v. 2, p. 1137–1143. Disponível em: <https://ai.stanford.edu/~ronnyk/accEst.pdf>. Acesso em: 20 mar. 2025.

KVAMME, Håvard; BORGAN, Ørnulf. The brier score under administrative censoring: Problems and solutions. **arXiv preprint**, [s. l.], 2019. ArXiv:1912.08581. Disponível em: <https://arxiv.org/abs/1912.08581>. Acesso em: 15 out. 2024.

LAFRAIA, João Ricardo Baruso. **Manual de confiabilidade, Manutenibilidade e Disponibilidade**. Rio de Janeiro: Qualitymark, 2001.

LU, Muyang; GULER, S. Ilgin. **Comparison of Random Survival Forest with Accelerated Failure Time-Weibull model for bridge deck deterioration**. 2022. Disponível em: https://www.researchgate.net/publication/359136114_Comparison_of_Random_Survival_Forest_with_Accelerated_Failure_Time-Weibull_Model_for_Bridge_Deck_Deterioration. Acesso em: 13 abr. 2025.

MORADI, Narges; HABIBIRAD, Ahmad; PANAHI, Hamed. Leveraging neural networks for robust survival estimation in cox proportional hazards model with censored data. **Communications in Statistics: Case Studies, Data Analysis and Applications**, Abingdon, UK, v. 10, n. 3–4, p. 349–364, Nov. 2024. DOI: 10.1080/23737484.2024.2439847. Disponível em: <https://www.tandfonline.com/doi/full/10.1080/23737484.2024.2439847>. Acesso em: 20 mar. 2025.

MURPHY, Kevin P. **Machine learning: a probabilistic perspective**. Cambridge, MA: The MIT Press, 2012. (Adaptive Computation and Machine Learning).

NELSON, Wayne B. **Accelerated testing: statistical models, test plans, and data analyses**. Hoboken, NJ: Wiley, 2004.

O'CONNOR, Andrew N.; MODDARES, Mohammad; MOSLEN, Ali. **Probability distributions used in reliability engineering**. College Park, MD: Center for Risk and Reliability, 2016.

OLIVEIRA, Tiago Almeida *et al.* Comparação de random survival forest e modelo de cox com relação a performance de previsão: Um estudo de caso. **Sigmae**, Alfenas, MG, v. 8, n. 2, p. 490–508, Jul./Dez. 2019. DOI: 10.5935/1679-3951.20190046. Disponível em: <https://publicacoes.unifal-mg.edu.br/revistas/index.php/sigmae/article/view/1003>. Acesso em: 02 jan. 2025.

PHAM, Hoang. **Statistical reliability engineering: methods, models, and applications**. Cham, Switzerland: Springer, 2022.

Revista Manutenção. Distribuições de vida da engenharia de confiabilidade. **Revista Manutenção**, São Paulo, 2023. Disponível em: <https://revistamanutencao.com.br/literatura/tecnica/confiabilidade/distribuicoes-de-vida-da-engenharia-de-confiabilidade.html>. Acesso em: 13 abr. 2025.

REZAEIZADEH, Amin; MASTELLONE, Silvia. Reliability-optimized space vector modulation (ro-svm) for semiconductors lifetime enhancement. *In: PCIM EUROPE, 2024, Nuremberg, Germany. International Exhibition and Conference for Power Electronics, Intelligent Motion, Renewable Energy and Energy Management*. Berlin, Germany: VDE, 2024. p. 1681–1687. DOI: 10.30420/566262230. Disponível em: <https://doi.org/10.30420/566262230>. Acesso em: 05 set. 2024.

SÁ, João Diego Conceição de. **Estudo de engenharia de confiabilidade e aplicação de ferramenta de inteligência artificial na gestão de ativos de uma unidade industrial na Amazônia**. Dissertação (Dissertação (Mestrado Profissional em Engenharia de Processos)) — Universidade Federal do Pará, Belém, 2021. Disponível em: https://repositorio.ufpa.br/bitstream/2011/13587/1/Dissertacao_EstudoEngenhariaConfiabilidade.pdf. Acesso em: 13 abr. 2025.

SAEED, Amna *et al.* Random survival forest model for early prediction of alzheimer’s disease conversion in early and late mild cognitive impairment stages. **PLoS One**, San Francisco, CA, v. 19, n. 2, p. e0314725, Feb. 2024. DOI: 10.1371/journal.pone.0314725. Disponível em: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0314725>. Acesso em: 13 abr. 2025.

SIMIONATO, Daniel. **Estudo e comparação das técnicas de validação cruzada desenvolvidas para séries temporais**. Dissertação (Dissertação (Mestrado em Estatística)) — Universidade de São Paulo, São Paulo, 2022. Disponível em: https://www.teses.usp.br/teses/disponiveis/45/45133/tde-19102022-162948/publico/DanielSimionato_MestradoProfissional.pdf. Acesso em: 08 mar. 2025.

SONABEND, Raphael; BENDER, Andreas. **Machine Learning in Survival Analysis**. Boca Raton, FL: CRC Press, 2025. E-book. Disponível em: <https://www.mlsabook.com>. Acesso em: 20 mar. 2025.

TAKAHASHI, Toshiyuki. Study of statistical failure rate evaluation for long life equipment based on operational data. *In: INTERNATIONAL SYMPOSIUM ON HIGH VOLTAGE ENGINEERING (ISH), 23., 2023, Glasgow, UK. International Symposium on High Voltage Engineering (ISH)*. London, UK: IET, 2023. p. 1203–1207. DOI: 10.1049/icp.2024.0786.

Disponível em: <https://doi.org/10.1049/icp.2024.0786>. Acesso em: 29 out. 2024.

TALEBI, Shaw. **10 Decision Trees are Better Than 1: Breaking down bagging, boosting, Random Forest, and AdaBoost.** [S. l.]: TDS Archive, 2023. Disponível em: <https://medium.com/data-science/10-decision-trees-are-better-than-1-719406680564>. Acesso em: 20 mar. 2025.

THOMPSON, Charles C.; BARRIGA, Claudia I. Relationship between historical trends, equipment age, maintenance, and circuit breaker failure rates. **IEEE Transactions on Industry Applications**, New York, v. 55, n. 6, p. 5699–5707, Nov./Dez. 2019. DOI: 10.1109/TIA.2019.2937927. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8815735>. Acesso em: 01 fev. 2025.

UNO, Hajime *et al.* On the c-statistics for evaluating overall adequacy of risk prediction procedures with censored survival data. **Statistics in Medicine**, Hoboken, NJ, v. 30, n. 10, p. 1105–1117, Mai. 2011. DOI: 10.1002/sim.4154. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3079915/>. Acesso em: 19 dez. 2024.

VELOSO, Luiza Tuler. **Um estudo comparativo de técnicas de validação cruzada aplicadas a modelos para dados desbalanceados.** Tese (Tese (Doutorado em Estatística)) — Universidade de São Paulo, São Paulo, 2022. Disponível em: https://www.teses.usp.br/teses/disponiveis/45/45133/tde-08082022-152547/publico/LuizaTulerVeloso_Doutorado.pdf. Acesso em: 05 nov. 2024.

XUE, Jingyuan *et al.* **Survival analysis with machine learning for predicting Li-ion battery remaining useful life.** 2025. ArXiv preprint arXiv:2503.13558 [cs.LG]. Disponível em: <https://arxiv.org/html/2503.13558>. Acesso em: 13 abr. 2025.

YE, Zhenggeng *et al.* Competing failure modeling for performance analysis of automated manufacturing systems with serial structures and imperfect quality inspection. **IEEE Transactions on Industrial Informatics**, New York, v. 16, n. 10, p. 6476–6486, Oct. 2020. DOI: 10.1109/TII.2020.2967030. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8961119>. Acesso em: 18 set. 2024.

ZHANG, Xiaoyan *et al.* MRI-based random survival forest model improves prediction of progression-free survival to induction chemotherapy plus concurrent chemoradiotherapy in locoregionally advanced nasopharyngeal carcinoma. **BMC Cancer**, London, v. 22, n. 1, p. 741, Jul. 2022. DOI: 10.1186/s12885-022-09832-x. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC9261049/>. Acesso em: 28 fev. 2025.