

**UNIVERSIDADE FEDERAL DA PARAÍBA - UFPB
CENTRO DE TECNOLOGIA - CT
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL E
AMBIENTAL – PPGECA
DOUTORADO EM ENGENHARIA CIVIL E AMBIENTAL**

MAISA BEATRIZ MARINHO FAUSTO DA SILVA

Modelagem explicativa para avaliação do estado de condição de
pontes rodoviárias quanto ao julgamento de insuficiência
estrutural a partir de relatórios de inspeção

ÁREA DE CONCENTRAÇÃO: ENGENHARIA URBANA

João Pessoa, PB – Brasil

Setembro de 2024

UNIVERSIDADE FEDERAL DA PARAÍBA - UFPB
CENTRO DE TECNOLOGIA - CT
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL E
AMBIENTAL – PPGECA
DOUTORADO EM ENGENHARIA CIVIL E AMBIENTAL

MAISA BEATRIZ MARINHO FAUSTO DA SILVA

**Modelagem explicativa para avaliação do estado de condição de
pontes rodoviárias quanto ao julgamento de insuficiência
estrutural a partir de relatórios de inspeção**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Civil e Ambiental do Centro de Tecnologia da Universidade Federal da Paraíba, como requisito à obtenção do título de Doutora em Engenharia Civil e Ambiental.

Área de Concentração: Engenharia Urbana

**Orientador: Prof. Dr. Ricardo
Almeida de Melo**

João Pessoa, PB - Brasil

Setembro de 2024

Catálogo na publicação
Seção de Catalogação e Classificação

S586m Silva, Maisa Beatriz Marinho Fausto da.

Modelagem explicativa para avaliação do estado de condição de pontes rodoviárias quanto ao julgamento de insuficiência estrutural a partir de relatórios de inspeção / Maisa Beatriz Marinho Fausto da Silva. - João Pessoa, 2024.

165 f. : il.

Orientação: Ricardo Almeida de Melo. Tese
(Doutorado) - UFPB/CT.

1. Pontes rodoviárias - Avaliação. 2. Dados de inspeções - Pontes. 3. Insuficiência estrutural - Pontes. 4. Modelo de regressão logística. 5. Modelos de Machine Learning. I. Melo, Ricardo Almeida de. II. Título.

UFPB/BC

CDU 625.745.12(043)

Modelagem explicativa para avaliação do estado de condição de pontes rodoviárias quanto ao julgamento de insuficiência estrutural a partir de relatórios de inspeção

MAISA BEATRIZ MARINHO FAUSTO DA SILVA

Tese apresentada ao Programa de Pós-graduação em Engenharia Civil e Ambiental da Universidade Federal da Paraíba, defendida em setembro de 2024 e aprovada pela banca examinadora, constituída pelos professores:

Documento assinado digitalmente
 **RICARDO ALMEIDA DE MELO**
Data: 30/09/2024 16:42:38-0300
Verifique em <https://validar.iti.gov.br>

Ricardo Almeida de Melo, Dr. - Orientador (UFPB)

Documento assinado digitalmente
 **ROBERTO LEAL PIMENTEL**
Data: 08/10/2024 08:26:11-0300
Verifique em <https://validar.iti.gov.br>

Roberto Leal Pimentel, Dr. – Avaliador interno (UFPB)

Documento assinado digitalmente
 **ANGELO VIEIRA MENDONÇA**
Data: 02/10/2024 13:55:07-0300
Verifique em <https://validar.iti.gov.br>

Ângelo Vieira Mendonça, Dr. Avaliador interno (UFPB)

Documento assinado digitalmente
 **WILLIAM DE PAIVA**
Data: 02/10/2024 08:38:43-0300
Verifique em <https://validar.iti.gov.br>

William de Paiva, Dr. Avaliador externo (UEPB)

Documento assinado digitalmente
 **ADRIANA DE PAULA LACERDA SANTOS**
Data: 02/10/2024 11:40:29-0300
Verifique em <https://validar.iti.gov.br>

Adriana de Paula Lacerda Santos, Dra. Avaliadora externa (UFPR)

João Pessoa, PB - Brasil

Setembro de 2024

AGRADECIMENTOS

A Deus, pela seu amor, bondade e infinitas misericórdias reveladas para comigo na pessoa do seu filho Jesus. Ele, que é a fonte inesgotável de sabedoria e inteligência sempre me amparou através do seu Espírito e da Sua palavra. Louvado seja o teu nome, Senhor! A minha família, pai, Manoel, mãe, Maisa, e irmãs, Miriam e Midiam, por sempre me incentivarem e acreditarem em mim, quando nem eu mesmo acreditei, vocês são o meu porto seguro. Ao meu saudoso avô, João Marinho, *in memoriam*, por tudo que me ensinou como um simples pescador. Manoel e Laudicéia, meus avós paternos, que me enchem de amor e me tratam como doutora desde o abc. Ao meu esposo, André, pelo amor, paciência e parceria, te amo. Aos meus amados filhos, João Pedro e Manoela, que eu consiga ser um exemplo para vocês, e eu nem estou falando de Ciência, vocês são minha maior motivação. A minha sogra, Elisama, por cada gesto de cuidado e carinho. Ao prof. Ricardo pela orientação, sua maneira gentil de tratar as pessoas, seu jeito ainda que tímido nas trocas e conversas foram importantes, sempre encontrei em você compreensão. Aos colegas do LAPAV, Antônio, Ingrid, Rafaela, Vinícius, Denner, Juliana e Amanda, por cada troca e boas conversas durante o longo período do doutorado. A João, pela parceria nesse grande desafio que foi trabalhar com pontes, você foi essencial nesse processo, quantos medos, incertezas e descobertas ao longo dessa caminhada, obrigada por sua dedicação a pesquisa, mais que isso, por sua amizade. Ao professor João Aguinaldo, pelo direcionamento inicial na parte estatística. Ao DNIT-PB, na pessoa do Engenheiro José Antônio, chefe de serviços de planejamento e projetos, por toda orientação nos transmite necessários para aquisição dos dados do SGO. A Rosane, DNIT-DF, por tirar todas as minhas dúvidas concernentes ao acesso do SGO. Aos amigos, Pedro e Camila, vocês dividiram as cargas comigo, me incentivaram e acreditaram na pesquisadora que habita em mim, mais que isso, muitas vezes deixaram os seus afazeres para me ajudar, são verdadeiros presentes, que desejo levar para o resto da minha vida. A Erivaldo, uma grata surpresa, aliás providência divina, você chegou no momento oportuno, seu conhecimento estatístico é admirável, sua generosidade em dividir comigo nunca será esquecida. A minha amiga Ana Paula, que assim como eu dividiu-se, entre ser, mãe, esposa e pesquisadora, quantas trocas tivemos, nunca esquecerei, dividimos angustias e agora, com fé em Deus celebramos as vitórias. Aos professores e servidores do PPGECA/UEPB. À CAPES/FAPESQ pela bolsa de estudos. Enfim, a todos quanto contribuíram direto e indiretamente na realização dessa pesquisa.

“.... Ao diligente a sua alma se fartará...Trecho da Bíblia”

RESUMO

Partido do pressuposto da importância do estudo contínuo de elementos que compõe a infraestrutura urbana, tais como as das Obras de Artes Especiais (OAEs), que são pontes, pontilhões, viadutos e passagens inferiores do Brasil; a pesquisa propõe uma modelagem explicativa/analítica de informações oriundas de inspeções disponíveis no SGO/DNIT, na intenção de avaliar a possível relação entre os pareceres de avaliadores com as características das pontes no julgamento de insuficiência estrutural, bem como a relação das notas atribuídas ao estado de condição. O procedimento é iniciado selecionando as variáveis importantes (*stepwise backward*) para explicar os pareceres dos avaliadores no tocante a insuficiência estrutural com base em uma análise preliminar usando a regressão logística binomial. O mesmo procedimento é realizado para as notas atribuídas do estado de condição utilizando a regressão logística ordinal. Em seguida, são realizadas as etapas, de análise preditiva com 6 (seis) algoritmos e a verificação de acurácia destes a partir de validação cruzada na modelagem do julgamento de insuficiência estrutural. Ainda aplicou-se as redes bayesianas para verificar as relações entre as variáveis independente, isso no julgamento da insuficiência estrutural, bem como em relação as notas atribuídas ao estado de condição. Foi possível atestar que de 12 (doze) características das pontes, 5 (cinco), idade, tipo de estrutura, largura da pista e outras duas relacionadas aos danos encontrados nelas, são as mais relevantes inicialmente para explicar o julgamento de insuficiência estrutural. O modelo logístico binomial indicou uma correta classificação para 82,73% dos registros investigados. Com o método *cross-validation* o modelo de regressão logística binomial teve a maior acurácia de 80,76% e nos modelos de *machine learning* a acurácia máxima observada foi de 83,40%. No modelo logístico ordinal as variáveis selecionadas (*stepwise backward*) para a modelagem foram: deslocamento de concreto com armadura exposta; concreto desagregado com armadura exposta e oxidada; oxidação do ferro; idade da ponte; largura da pista e tipo de estrutura. As melhores taxas de acerto foram nas classificações para as notas 1 (92,2%) e 2 (78,0%). Por fim, a partir dos algoritmos avaliou-se 20 cenários onde se observou o papel preponderante dos danos de deslocamento de concreto com armadura exposta e concreto desagregado com armadura exposta e oxidada, para o julgamento de insuficiência estrutural e para a atribuição das notas de condição. A boa qualidade do ajuste dos modelos de regressão logística e dos algoritmos de *machine learning* foi um indicativo de que seria possível formular um modelo com capacidade preditiva suficiente para auxiliar nas classificações das pontes quanto a insuficiência estrutural e atribuição das notas para o estado de condição.

Palavras-chaves: Pontes, Dados de inspeções, Insuficiência estrutural, Modelo de regressão logística, Modelos de *Machine Learning*.

ABSTRACT

Starting from the assumption of the importance of the continuous study of elements that make up urban infrastructure, such as those of Special Arts Works (OAEs), which are bridges, viaducts and underpasses in Brazil; the research proposes an explanatory/analytical modeling of information from inspections available at SGO/DNIT, with the intention of evaluating the possible relationship between the opinions of evaluators with the characteristics of the bridges in the judgment of structural insufficiency, as well as the relationship of the scores attributed to the condition state. The procedure begins by selecting the important variables (stepwise backward) to explain the evaluators' opinions regarding structural insufficiency based on a preliminary analysis using binomial logistic regression. The procedure begins by selecting the important variables (stepwise backward) to explain the evaluators' opinions regarding structural insufficiency based on a preliminary analysis using binomial logistic regression. The same procedure is carried out for the scores assigned for the condition state using ordinal logistic regression. Next, the steps of predictive analysis are carried out with 6 (six) algorithms and the verification of their accuracy based on cross-validation in the modeling of the structural insufficiency judgment. Bayesian networks were also applied to verify the relationships between the independent variables, this in the judgment of structural insufficiency, as well as in relation to the scores attributed to the condition state. It was possible to attest that out of 12 (twelve) characteristics of the bridges, 5 (five), age, type of structure, lane width and two others related to the damage found on them, are the most relevant initially to explain the judgment of structural insufficiency. The binomial logistic model indicated a correct classification for 82.73% of the records investigated. With the cross-validation method, the binomial logistic regression model had the highest accuracy of 80.76% and in the machine learning models the maximum accuracy observed was 83.40%. In the ordinal logistic model, the variables selected (stepwise backward) for modeling were: spalling of concrete with exposed reinforcement; disaggregated concrete with exposed and oxidized reinforcement; iron oxidation; age of the bridge; lane width and type of structure. The best success rates were in classifications for grades 1 (92.2%) and 2 (78.0%). Finally, using the algorithms, 20 scenarios were evaluated in which the preponderant role of damage caused by the spalling of concrete with exposed reinforcement and disintegrated concrete with exposed and oxidized reinforcement was observed, for the judgment of structural insufficiency and for the attribution of condition notes. The good quality of adjustment of the logistic regression models and machine learning algorithms was an indication that it would be possible to formulate a model with sufficient predictive capacity to assist in classifying bridges regarding structural insufficiency and assigning scores for condition status.

Keywords: Bridges, Inspection data, Structural insufficiency, Logistic regression model, Machine Learning models.

LISTA DE FIGURAS

Figura 1 - Elementos componentes de uma ponte, (A) e (B)	19
Figura 2 - Número de publicações por ano e base de dados (busca geral).....	30
Figura 3 - Rede de co-ocorrências de palavras-chave em busca geral.	31
Figura 4 - Percentual de publicação por área de conhecimento (Web of Science)	32
Figura 5 - Percentual de publicação por área de conhecimento (Scopus).....	32
Figura 6 - Publicações por países (Scopus).....	33
Figura 7 - Publicações por países (Web of Science)	34
Figura 8 - Número de publicações por ano e base de dados (busca específica).....	35
Figura 9 - Rede de co-ocorrências de palavras-chave em busca específica.	36
Figura 10 - Componentes básicos do SGO	48
Figura 11 - Mapa conceitual da pesquisa	73
Figura 12 - Esquema genérico do desenvolvimento do trabalho	74
Figura 13 - Mapa de pontes rodoviárias localizadas no Estado da Paraíba.....	78
Figura 14 - Notas do estado de condição das pontes.....	78
Figura 15 - Representação gráfica do teste de Friedman e o teste de Nemenyi.....	96
Figura 16 - Gráfico usado na rede bayesiana discreta.....	100
Figura 17 - Rede bayesiana para nota atribuída	108
Figura 18 - Rede bayesiana para nota atribuída excluindo a oxidação do ferro.....	109

LISTA DE TABELAS

Tabela 1 - Colapsos de pontes	22
Tabela 2 - Inspeção de pontes na Coréia do Sul.....	38
Tabela 3 - Tipos e intervalos de inspeções nos EUA	38
Tabela 4 - Tipos de inspeção de ponte no Reino Unido	39
Tabela 5 - Inspeções realizadas nas pontes da Alemanha	40
Tabela 6 - Tipos de inspeções realizadas na Dinamarca	40
Tabela 7 - Inspeções de pontes na África do Sul.....	41
Tabela 8 - Tipos de inspeções da Suécia	42
Tabela 9 - Frequência das inspeções do Brasil.....	42
Tabela 10 - Manuais, guias e normas para a manutenção em pontes	44
Tabela 11 - Categorias de gerência de pontes	46
Tabela 12 - Cenário mundial dos Sistemas de Gerência de Pontes.....	51
Tabela 13 - Escala de avaliação do estado de condição de pontes (EUA)	54
Tabela 14 - Classificação de condição da ponte do Reino Unido	56
Tabela 15 - Classificação da condição de OAE	57
Tabela 16 - Classificação da condição de OAE segundo a NBR 9452 (ABNT, 2016). 58	
Tabela 17 - Classificação da condição de pontes de alguns países	59
Tabela 18 - Vantagens e limitações das abordagens utilizadas nos modelos de deterioração	62
Tabela 19 - Síntese da bibliografia consultada segundo autores e abordagens	64
Tabela 20 - Classificações do estado de condição da OAE.....	75
Tabela 21 - Processo de seleção Stepwise.....	87
Tabela 22 - Modelo selecionado pelo Stepwise	87
Tabela 23 - Modelo I contendo apenas variáveis significativas e sem a largura da pista	88
Tabela 24 - Modelo II contendo apenas parâmetros significativos e sem a idade da ponte	89
Tabela 25 - Comparação dos modelos com parâmetros significativos	90
Tabela 26 - Comparação dos algoritmos	93
Tabela 27 - Valores da acurácia a partir de 30 avaliações por Cross-Validation com 10 folds	94
Tabela 28 - Rank dos algoritmos pela acurácia	95

Tabela 29 - Valores da estatística Kappa resultante de 30 avaliações por cross-validation com 10 folds	97
Tabela 30 - Processo Stepwise Backward para a regressão logística Ordinal.....	101
Tabela 31 - Variáveis selecionadas pelo Stepwise	102
Tabela 32 - Modelo I	103
Tabela 33 - Modelo II acrescido da idade da ponte.....	104
Tabela 34 - Avaliação da acurácia e AUC por classe da variável dependente.....	105
Tabela 35 - Testes de independência condicional na rede bayesiana.....	107
Tabela 36 - Avaliação do parecer de insuficiência estrutural nos cenários pela regressão logística binomial	111
Tabela 37 - Avaliação do parecer de insuficiência estrutural nos cenários pelo algoritmo de Support Vector Machine (SVM).....	113
Tabela 38 - Avaliação do parecer de insuficiência estrutural nos cenários pelas redes bayesianas.....	115
Tabela 39 - a avaliação dos cenários sob a perspectiva da nota atribuída pelo avaliador	117

LISTA DE QUADROS

Quadro 1 - Variáveis explicativas para avaliação do estado de condição.....	65
Quadro 2 - O quadro sintetiza algumas referências de trabalhos atuais QC/QA	71
Quadro 3 - Resumidas das características de pontes do estudo	76

LISTA DE ABREVIATURAS E SIGLAS

AASHTO - American Association of State Highway and Transportation Officials

ABMS - Sistema de gerência de pontes (EUA)

ABNT - Associação Brasileira de Normas Técnicas

ANN - *Artificial Neural Network*

ANTT - Agência Nacional de Transporte

APTBMS - Sistema de gerência de pontes (Itália)

ARTESP - Agência de Transporte do Estado de São Paulo

ASCE - *America Society of Civil Engineers*

BATMAN - Sistema de gerência de pontes (Suécia)

BCI - *Bridge Condition Index* (Denominação do IC utilizado no Canadá)

BMS - *Bridge Management Systems* (Sistemas de Gerência de Pontes)

BP- MLP - *Back Propagation Multi-Layer Perceptron*

BPM - *Backward Prediction Model*

BRIDGIT - Sistema de Gerência de Pontes com maior utilização (Europa e EUA)

BRIME - Sistema de gerência de pontes (Reino Unido)

CBMS - Sistema de gerência de pontes (China)

CBR - *Case-based Reasoning Models*

COSMO - Sistema de gerência de pontes (Inglaterra)

CR - *Condition Rating*

DANBRO - Sistema de gerência de pontes (Dinamarca)

DER - Departamento de Estradas de Rodagem

DISK - Sistema de gerência de pontes (Holanda)

DNIT - Departamento Nacional de Infraestrutura de Transporte

DOTs - *Department of Transportation* (EUA)

EIRSPAN - Sistema de gerência de pontes (Irlanda)

EM - *Expectation Maximization*

FBMS - Sistema de gerência de pontes (Finlândia)

FHWA - *Federal Highway Administration*

GBMS - Sistema de gerência de pontes (Alemanha)

GOA - Sistema de gerência de pontes (Portugal)

GRDR - Sistema de gerência de pontes (Chile)

IC - Índice de Condição

IPR - Instituto de Pesquisas Rodoviárias

IQOA - *Image de la Qualité des Ouvrages d'Art* (denominação do IC usado na França)

IQOA - Sistema de gerência de pontes (França)

J-BMS - *The Bridge Management System in Japan*

KRBMS - Sistema de gerência de pontes (Coréia do Sul)

KUBA-MS - Sistema de gerência de pontes (Suíça)

MBEI - *Guide Manual for Bridge Element Inspection*

MLIT - *Ministry of Land, Infrastructure, Transport and Tourism* (Japão)

MLP - *Multi-Layer Perceptron*

MOHURD - *Ministry of Housing and Urban-Rural Development of the People's Republic of China*

MOLIT - *Ministry of Land, Infrastructure, and Transport* (Coréia)

MOO - *Multi-objective Optimization*

MOT - *Ministry of Transport of the People's Republic of China*

MPT - Matriz de Probabilidades de Transição de Estados

MT - Ministério dos Transportes (MT),

NBI - *National Bridge Inventory* (Inventário de Pontes Norte-Americano)

NBIS - *National Bridge Inspection Standards*

NBR - Norma Brasileira

NCHRP - *National Cooperative Highway Research Program*

OAE - Obra de Arte Especial

OBMS - Sistema de gerência de pontes (Canadá)

PONTIS - Sistema de gerência de pontes com maior utilização na América do Norte e Europa

PROART - Programa de Manutenção e Reabilitação de Estruturas

QBMS - Sistema de gerência de pontes (Canadá)

RPIBMS - Sistema de gerência de pontes (Japão)

SANRAL - *South Africa National Road Agency Limited*

SCANPRINT - Sistema de gerência de pontes (Portugal)

SGO - Sistema de Gestão de Obras Especiais (Brasil)

SIB-BAUWERKE - Sistema de gerência de pontes (Alemanha)

SIGMA - Sistema de gerência de pontes (Argentina)

SIPUMEX - Sistema de gerência de pontes (México)

SMOK - Sistema de gerência de pontes (Polônia)

SOO - *Single-objective Optimization*

SRA - *Swedish Road Administration*

SZOK - Sistema de gerência de pontes (Polônia)

TCU - Tribunal de Contas da União

TDNNs - *Time Delay Neural Networks*

USDOT - *United States Department of Transportation*

VMD - Volume Médio Diário

SUMÁRIO

RESUMO.....	7
ABSTRACT	8
LISTA DE FIGURAS.....	9
LISTA DE TABELAS.....	10
LISTA DE QUADROS.....	12
1. INTRODUÇÃO	19
1.1 ASPECTOS GERAIS.....	19
1.2 JUSTIFICATIVA.....	21
1.3 RELEVÂNCIA do estudo	23
1.4 MOTIVAÇÃO E LACUNAS	25
1.5 HIPÓTESE	27
1.6 OBJETIVOS.....	27
1.6.1 <i>Objetivo geral:</i>	27
1.6.2 <i>Objetivos específicos:</i>	27
1.7 DELIMITAÇÃO E LIMITAÇÃO DO ESTUDO	28
1.8 ORGANIZAÇÃO DO DOCUMENTO DE TESE	28
2. REVISÃO BIBLIOGRÁFICA.....	29
2.1 LEVANTAMENTO BIBLIOMÉTRICO.....	29
2.2 INSPEÇÕES REALIZADAS EM PONTES	37
2.3 ALGUNS MANUAIS, GUIAS E NORMAS UTILIZADAS PARA INSPEÇÃO	43
2.4 SISTEMAS DE GERÊNCIA DE PONTES.....	46
2.5 CICLO DE VIDA, VIDA ÚTIL, DESEMPENHO E CLASSIFICAÇÕES DO ESTADO DE CONDIÇÃO DAS PONTES.....	52
2.5.1 Ciclo de vida	52
2.5.2 Vida útil.....	53
2.5.3 Desempenho.....	53
2.5.4 Classificações do Estado de condição das pontes.....	54
2.6 ABORDAGENS PARA AVALIAÇÃO DO ESTADO DE CONDIÇÃO	60
2.7 ANÁLISE CRÍTICA DOS PRINCIPAIS MÉTODOS UTILIZADOS NA AVALIAÇÃO DE PONTES.....	63
2.8 CONTROLE E GARANTIA DA QUALIDADE em dados de infraestrutura.....	69
3. MÉTODOS DO TRABALHO	73
3.1 CARACTERIZAÇÃO DO BANCO DE DADOS.....	74
3.1.2 <i>Aquisição e criação de banco de dados próprio</i>	75
3.1.3 <i>Características das pontes</i>	75
3.2 REGRESSÃO LOGÍSTICA E O PROCEDIMENTO DE SELEÇÃO DE VARIÁVEIS.....	79

3.2.1 Regressão logística binomial para avaliar o julgamento de insuficiência estrutural	79
3.2.2 Regressão Logística Ordinal para avaliar as notas atribuídas ao estado de condição	81
3.3 REDES BAYESIANAS	82
3.4 ALGORITMOS DE MACHINE LEARNING	82
3.4.1 Regressão Logística	83
3.4.2 Naive Bayes	83
3.4.3 Random Forest	83
3.4.4 K-nearest Neighbours	84
3.4.5 Support Vector Machine	84
3.4.6 Redes Neurais Perceptron Multicamadas	84
3.5 SOFTWARE UTILIZADO PARA ANÁLISE E MODELAGENS	85
4. RESULTADOS E DISCUSSÕES	86
4.1. INVESTIGAÇÃO DA RELAÇÃO ENTRE JULGAMENTO DA INSUFICIÊNCIA ESTRUTURAL E CARACTERÍSTICAS DAS PONTES	86
4.1.1 Abordagem do julgamento da insuficiência estrutural a partir da regressão logística binomial	87
4.1.2 Abordagem do julgamento da insuficiência estrutural a partir de algoritmos de Machine learning	92
4.1.3 Abordagem do julgamento da insuficiência estrutural a partir de Redes Bayesianas Discretas	99
4.2. MODELAGEM EXPLICATIVA DA NOTA ATRIBUÍDA ao estado de condição E AS CARACTERÍSTICAS REGISTRADAS DAS PONTES	101
4.2.1 Abordagem explicativa da nota atribuída do estado de condição a partir da regressão logística ordinal	103
4.3 MODELO DE REDES BAYESIANAS DISCRETAS PARA AVALIAÇÃO DA NOTA ATRIBUÍDA	105
4.4 CENÁRIOS HIPOTÉTICOS	109
4.4.1 Julgamento esperado no parecer dos avaliadores é examinado com base em um modelo de regressão logística binomial	109
4.4.2 Parecer esperado investigados utilizando um dos algoritmos que apresentaram o melhor desempenho na abordagem de machine learning	112
4.4.3 a avaliação do julgamento de insuficiência estrutural a partir da rede bayesiana	114
5. CONCLUSÕES E RECOMENDAÇÕES	119
5.1. DIVERSAS MODELAGENS PARA A DETERIORAÇÃO DAS OAES	119
5.2 ESTADO DE CONDIÇÃO DAS OAES	119
5.3.1 Modelo logístico para explicar o julgamento de insuficiente estrutural	120
5.3.2 Adequação de diferentes métodos preditivos para o julgamento de insuficiência estrutural	121
5.3.3 Modelo logístico ordinal para explicar a nota atribuída ao estado de condição	122


<i>5.3.4 Geração de Cenários</i>	122
5.4 DIFICULDADES ENCONTRADAS E PRINCIPAL CONTRIBUIÇÃO	123
5.5 RECOMENDAÇÕES PARA TRABALHOS FUTUROS E LIMITAÇÕES	124
REFERÊNCIAS BIBLIOGRÁFICAS	125
ANEXO I – PROGRAMAÇÃO EM R PARA APLICAÇÃO DOS ALGORITMOS E OBTENÇÃO DOS CENÁRIOS	140

1. INTRODUÇÃO

1.1 ASPECTOS GERAIS

As Obras de Artes Especiais (OAEs) incluem estruturas como pontes, pontilhões, viadutos e passarelas. Segundo a NBR 9452 (2016), uma ponte é uma estrutura projetada para transpor obstáculos com um vão livre superior a seis metros (DNIT 010/2004 – PRO). O manual de manutenção do Departamento Nacional de Infraestrutura de Transportes (DNIT) define a ponte como uma estrutura que suporta uma via para passagem de veículos e cargas sobre uma depressão ou obstrução, como água ou estradas (NBR 7188:2013). Seus principais elementos são a superestrutura, que vence o vão e suporta o tráfego; a mesoestrutura, que transfere a carga para a fundação; a infraestrutura, que transmite a carga para o solo; e os encontros, que conectam a ponte à rodovia. Os referidos elementos estão indicados na Figura 1.

Figura 1 - Elementos componentes de uma ponte, (A) e (B)



Fonte: Vitório (2002)

As pontes se classificam quanto a finalidade em: 1) rodoviária – para o tráfego rodoviário; 2) ferroviária – para o tráfego ferroviário; 3) rodoferroviária – para o tráfego misto composto pelos de veículos rodoviários e ferroviários; 4) passarela – para o tráfego de pedestres e ciclistas; e, 5) aeroviária – para o tráfego de aeronaves. Quanto aos

materiais empregados, as pontes podem ser: 1) de concreto (armado e/ou protendido); 2) metálicas; 3) mistas (aço/concreto, aço/madeira, etc.); 4) de pedra ou 5) de madeira. Em relação ao sistema estrutural adotado, são classificadas de pontes em laje cujos tabuleiros são constituídos apenas por laje, sem qualquer tipo de viga.

Essas estruturas são cruciais para a continuidade do tráfego e precisam de inspeções, diagnósticos, monitoramento e manutenção para manter um bom nível de serviço. Inspeções reúnem dados sobre o estado da ponte e resultam em relatórios detalhados, enquanto o diagnóstico avalia a adequação da ponte às vias. O monitoramento acompanha o desempenho da estrutura em condições reais de carga e uso. Segundo Marchetti (2013), uma ponte deve atender aos requisitos de funcionalidade, segurança, estética, economia e durabilidade, garantindo que suporte o tráfego, mantenha-se segura e esteticamente agradável, seja econômica e durável ao longo de sua vida útil.

Sendo assim, uma ponte, além de atender às funções para que foi construída, deverá ser funcional, segura, durável, econômica e estética. Entende-se por segura a obra que tem probabilidade de manter suas características ao longo da vida útil e que dá sinais quando precisa de manutenção. As pontes são consideradas como um ponto crítico nas rodovias – pois estão diretamente relacionadas à mobilidade e à segurança viária nas rodovias – por esse motivo são tratadas de forma separada na manutenção. Segundo a FHWA (2011), as atividades de conservação em OAEs são: substituição, reabilitação e manutenção.

A manutenção de pontes é tida como o conjunto de atividades que permitem manter a integridade estrutural em um nível adequado de uso (DNIT, 2016). A conservação de Obras de Arte Especiais (OAEs) rodoviárias é uma das atividades mais importantes, a serem executadas pelos setores públicos e privados responsáveis pelas rodovias. Sendo assim, os gestores de pontes precisam se tornar estratégicos, implementando processos sistemáticos de preservação de pontes como um componente integrante de seu gerenciamento. Um sistema de gerenciamento da manutenção em pontes busca uma abordagem equilibrada para preservação e substituição (FHWA, 2011).

A manutenção de pontes enfrenta desafios devido à sua idade avançada, aumento do tráfego e deterioração por impactos humanos e ambientais. Essa complexidade exige uma abordagem sistemática para ser eficaz, mas frequentemente a manutenção é feita de forma corretiva, quando a ponte já está muito deteriorada. Segundo Morcous (2000), as pontes são sistemas estruturais complexos que deterioram-se com o tempo devido a desgaste, fadiga, agentes ambientais, aumento de carga, problemas construtivos e

manutenção inadequada. Portanto, é essencial adotar métodos preventivos e sistemáticos para melhorar a gestão e a conservação dessas estruturas.

1.2 JUSTIFICATIVA

As Obras de Artes Especiais (OAEs) tendem a deteriorar-se ao longo de suas vidas úteis. Nos EUA, a *American Society of Civil Engineers* (ASCE, 2017) relata que quase 40% das 616.000 pontes registradas no *National Bridge Inventory* (NBI) estão próximas ou além da vida útil de 50 anos, com mais de 10% enfrentando restrições de carga. A *American Road and Transportation Builders Association* (ARTBA, 2020) estima que uma em cada três pontes precisa de reparo, reabilitação ou substituição, custando cerca de US\$ 164 bilhões. No Canadá, muitas das 74.316 pontes têm entre 25 e 75 anos, evidenciando uma "crise de ponte" devido ao envelhecimento das infraestruturas (KHANZADA, 2012).

Na Suíça, de 1000 pontes, entre 30 e 50 passam por reparos ou substituições anualmente, totalizando cerca de 5% (SCHELLENBERG *et al.*, 2016). No Japão, 18% das 400.000 pontes têm mais de 50 anos (MLIT, 2013). Na Coreia do Sul, em 2016 havia 30.983 pontes, com um aumento no número de pontes usadas por mais de 30 anos nos anos 90 e 2000 (MINISTRY of LAND, 2016). A Argentina possui mais de 3.000 OAEs construídas desde os anos 70, com idades próximas a 50 anos, período significativo para a deterioração rápida e acentuada desses tipos de estruturas (FARINÃ, 2015).

No Brasil existem aproximadamente 137.000 OAEs, em torno de 6.612 estão sob a responsabilidade do Departamento Nacional de Infraestrutura de Transportes (DNIT) e pelo menos 3.351, encontram-se em situações que variam de “condições precárias” a “mau estado de conservação”, estas OAEs foram construídas principalmente a partir da década de 40 (TIMERMAN, 2015). Em dados divulgados pelo Tribunal de Contas da União (TCU) está registrado que em torno de 75% das pontes existentes nas rodovias brasileiras que não estão sob o regime de concessão encontram-se em precário estado de conservação e necessitam de intervenções.

Apesar dos avanços nas técnicas de construção e materiais, o colapso de pontes ainda é frequente devido ao envelhecimento e deterioração das estruturas. As consequências de falhas totais ou parciais são graves, afetando a mobilidade, sobrecarregando o sistema de transportes e causando mortes. Isso destaca a necessidade urgente de evitar problemas relacionados à negligência e à falta de manutenção. Na

Tabela 1 estão registrados exemplos de colapsos de pontes em diversos países, evidenciando a importância de manter a integridade das infraestruturas.

Tabela 1 - Colapsos de pontes				
ANO	PAÍS	PONTE	MORTE	PROVÁVEL CAUSA
1967	EUA	<i>Silver Bridge</i>	46	Seção insuficiente e corrosão
1994	CORÉIA DO SUL	Ponte <i>Seongsu</i>	32	Problemas nas ligações soldadas
1997	BRASIL	Ponte dos Remédios (SP)	-	Capacidade resistente insuficiente
1998	PERU	Ponte sobre o rio <i>Piura</i> (norte)	26	Inundação
1999	CHINA	Ponte arco-íris	49	Desconhecida
2000	EUA	<i>Lowe's Motor Speedway Pedestrian Bridge</i> 3	-	Capacidade resistente insuficiente
2001	PORTUGAL	Ponte <i>Hintze</i>	70	Infraescavação
2005	BRASIL	Ponte sobre a represa do Capivari (PR)	-	Ruptura do aterro de uma das cabeceiras
2006	CANADÁ	<i>PS Concorde Boulevard</i>	5	Ruptura no apoio
2007	EUA	<i>Ponte Minneapolis I-35W</i>	12	Capacidade resistente insuficiente
2011	INDONESIA	<i>Kutai Kartanegara Bridgee</i>	-	-
2012	CHINA	Ponte <i>Yangmingtang</i>	-	-
2016	ÍNDIA	Ponte Calcutá	15	Desconhecida
2018	ITÁLIA	Ponte Morandi	39	Desconhecida
2018	BRASIL	Ponte do Bragueto (DF)	-	Corrosão de armadura
2018	EUA	<i>Florida int. Univ. Pedestrian Bridge</i>	-	-
2019	TAIWAN	Ponte de <i>Nanfangao</i>	-	Desconhecida
2019	BRASIL	Ponte do complexo Alça Viária (Pará)	-	Colisão de embarcação
2022	CHINA	<i>Xihuan interchange Bridge</i>	0-1	Erros construtivos

Fonte: adaptado de Branco (2013); Almeida (2013); Kim (2018), Jeong (2018), Oliveira (2019), Malerba (2024) e Tang (2024).

Devido aos vários episódios de colapsos de pontes no Brasil e no mundo, alguns sintetizados na Tabela 1, pode-se dizer que a atenção da comunidade técnica e científica para esses elementos, com vistas as atividades de inspeção, diagnóstico, monitoração e manutenção cresce cada vez mais. O interesse em manter as pontes em boas condições é global, pois estas fazem parte da infraestrutura básica e representam uma parcela significativa do patrimônio dos países.

Desse modo, a conservação de Obras de Arte Especiais (OAEs) rodoviárias é uma das atividades mais importantes a serem executadas pelos setores públicos e privados responsáveis pelas rodovias. A fase relativa à operação da ponte, a qual surge a solicitação de manutenção deve receber atenção por parte dos órgãos responsáveis. Vale ressaltar, que as demais fases do ciclo de vida devem ter suas tarefas monitoradas e integradas também. A falta de políticas e estratégias efetivas voltadas para a manutenção das obras públicas ao longo das últimas décadas intensificou um processo de desgaste e deterioração das rodovias, atingindo diretamente as Obras de Arte Especiais que, de modo geral, apresentam danos estruturais e funcionais (SILVA, 2018).

Os danos funcionais das OAEs, embora afetem elementos com vida útil inferior à da estrutura principal, podem acelerar a deterioração e reduzir a vida útil da ponte. Mendes (2009) destaca que, ao longo dos anos, as pontes enfrentam mudanças no volume de tráfego, capacidade de carga e número de eixos dos veículos. Essas mudanças, junto com atualizações nas normas de projeto e materiais utilizados, como a NBR 7188 (2013), que estabelece uma carga móvel de 450 kN, tornam a conservação dessas estruturas um grande desafio para a gestão pública.

1.3 RELEVÂNCIA DO ESTUDO

A falta de estratégias de manutenção resultou em uma lacuna nas informações sobre o real estado das obras de infraestrutura, especialmente das OAEs. Inspeções regulares são essenciais para coletar dados cadastrais e avaliar a segurança e funcionalidade dessas obras. O estado de condição das pontes é crucial para direcionar atividades de manutenção e deve ser integrado a um processo sistemático de inspeção, diagnóstico, monitoramento e manutenção. Compreender e prever o comportamento das pontes depende diretamente da avaliação de seu estado de condição.

Por isso, o estudo do comportamento das OAEs é um processo complexo, na medida em que, geralmente, se deve à ponderação ou combinação de vários fatores, nem sempre imediatamente identificáveis, e com uma distribuição considerável ao longo do tempo, cujos efeitos podem se manifestar, em uma redução considerável nos aspectos estruturais, funcionais, de conforto e segurança. Desse modo os sistemas de gerenciamento tentam quantificar e controlar o processo de deterioração por meio de estratégias de manutenção (CAÑAMARES, 2016).

Um sistema de gerenciamento de pontes concentra-se em criar um inventário a partir de inspeções, o que permite o registro histórico das estruturas e auxilia na identificação de estratégias de otimização para os problemas encontrados. Segundo, CHEN *et al.* (2019) os métodos de otimização são divididos em *Single-Objective Optimization* (SOO) e *Multi-Objective Optimization* (MOO). Os SOO, focados em um único objetivo, são simples, mas insuficientes para lidar com as múltiplas variáveis dos sistemas de gerenciamento de pontes, segundo Canãmares (2016). Por outro lado, os MOO, que abordam múltiplos objetivos, são amplamente utilizados para solucionar problemas complexos de otimização em várias áreas da engenharia, incluindo a gestão de pontes.

Manter as pontes rodoviárias com um bom desempenho estrutural e funcional, tornou-se uma complexa atividade de gestão, dada à quantidade de fatores intervenientes nesse processo, de modo que o emprego de um Sistema de Gerenciamento de Obras de Artes Especiais (SGO) é imprescindível para a melhor coordenação das atividades. Além disso, um SGO deve ser estruturado e respaldado por modelos capazes de suprir as demandas de previsão da deterioração das estruturas, otimização das atividades de manutenção, sistematização das avaliações oriundas de inspeção, dentre outras coisas.

As necessidades de gerenciamento de pontes são únicas, exigindo modelos que representem diferentes realidades. Modelos determinísticos, baseados em ferramentas estatísticas e de regressão, descrevem tendências a partir de dados históricos. Por outro lado, modelos estocásticos utilizam variáveis aleatórias para atribuir probabilidades a estados de condição. Complementando esses modelos, a inteligência artificial (IA) oferece técnicas como sistemas inteligentes, redes neurais artificiais e raciocínio baseado em casos, ampliando as capacidades de análise e previsão.

A comunidade científica tem se concentrado em desenvolver e aprimorar metodologias e ferramentas para avaliar o estado de condição das Obras de Artes Especiais (OAEs), otimizar a manutenção e sistematizar avaliações de inspeção. Modelos preditivos como extrapolação linear, regressão linear e não-linear, modelos de regressão logística, redes neurais artificiais, redes bayesianas, simulação e algoritmos de mineração de dados têm sido utilizados para prever o estado das pontes. Métodos como Cadeias de Markov e simulação Monte Carlo estão se tornando populares, mas enfrentam limitações por não fornecerem detalhes específicos sobre a deterioração de elementos individuais e por assumirem que a deterioração é independente do tempo, o que pode não refletir a

realidade (BUCHHEIT *et al.*, 2005; DIN; TANG, 2016; CHEN *et al.*, 2005; MIGLIACCIO *et al.*, 2014; ZHANG *et al.*, 2023; MA *et al.*, 2023).

A Inteligência Artificial, especialmente as Redes Neurais, é útil por modelar não linearidades automaticamente e lidar com entradas categóricas, incluindo múltiplas categorias ordinais. No entanto, um desafio é a dificuldade de interpretar os resultados quando usadas isoladamente, levando ao desenvolvimento de técnicas para melhorar a interpretação e ajustar parâmetros. Modelos também podem precisar de ajustes, detectáveis por estudos de sensibilidade, que variam conforme componentes, tipologias, materiais e agentes externos. Esses ajustes ajudam a identificar relações entre o Índice de Condição e variáveis internas e externas que afetam as pontes.

Alguns modelos de regressão são populares pela simplicidade em estabelecer relações explicativas, especialmente a regressão logística, que captura a natureza latente do desempenho de infraestruturas e variáveis dependentes discretas. No entanto, esses modelos podem precisar de ajustes para lidar com variáveis multinível discretas e classificações ordinais, como as usadas em pontes. A regressão logística ordinal, uma extensão da regressão multinomial, é adequada para modelar mudanças nas classificações de condição das pontes e tem sido aplicada na modelagem de acidentes, deterioração de tubulações, serviços de águas residuais e pontes (GOYAL *et al.*, 2017; RUCK; FRANCIS, 2017; HUANG, 2006).

1.4 MOTIVAÇÃO E LACUNAS

Arelados à gama de possibilidades em abordagens para modelar os dados catalogados das OAEs, há outros importantes fatores a serem considerados, como cenários de dados complexos, irregulares, desequilibrados e com muitas perdas de informações, além da qualidade desses registros, que são na maioria das vezes resultados de inspeções visuais. A subjetividade está presente no julgamento dos inspetores e, conseqüentemente, no valor atribuído ao estado de condição observado. Por isso, pesquisas estão em constante busca de ferramentas que possam auxiliar no panorama geral dessas avaliações (OZYÜKSEL; ÇIFTÇIOĞLU; NASER, 2024; WANG *et al.*, 2024; ALIPOUR *et al.*, 2017; LI, ALIPOUR; HARRIS, 2021; SRIKANTH; AROCKIASAMY, 2020; LIU; EL-GOHARY, 2020).

Determinar a condição geral de uma ponte com base nas condições individuais dos componentes é desafiador, pois exige a integração de falhas específicas em uma nota

global. Avaliadores utilizam seu conhecimento em engenharia de pontes para garantir avaliações precisas e consistentes, mas isso demanda inovação em métodos avançados. A tarefa é complexa por duas razões: as diretrizes de classificação devem ser interpretadas corretamente pelos inspetores, e as classificações dos componentes precisam refletir uma visão global das deficiências locais, exigindo experiência para uma avaliação holística e precisa.

A transição entre classificações de condição das pontes é imprecisa e subjetiva, dependendo do conhecimento e experiência dos inspetores, que avaliam como deficiências locais impactam o estado geral dos componentes. Devido a essa subjetividade, é desafiador atribuir classificações de forma consistente e precisa, o que demanda inovação em métodos de estimativa de classificação. Portanto, há uma necessidade de aprofundar estudos para parametrizar as características observadas e registradas com os julgamentos dos inspetores. A análise detalhada dos relatórios de inspeção, que muitas vezes contém descrições narrativas não exploradas, pode melhorar a qualidade dos dados sobre o estado das pontes e apoiar melhor as decisões de gestão da infraestrutura.

Na literatura internacional se discute sobre uma estrutura baseada em dados que estabelece um mapeamento entre as informações contidas nos relatórios de inspeção e as classificações de condição das pontes. Uma linha importante nesse contexto envolve a identificação de inconsistências ou anormalidade nos dados coletados. Diferentes abordagens de avaliação da qualidade dos dados, incluindo métodos estatísticos, agrupamento, detecção baseada em padrões, comparação de anos diferentes para identificar erros lógicos, entre outros; podem melhorar a qualidade dos dados sobre as condições das infraestruturas (LIU; EL-GOHARY, 2022; HENG *et al.*, 2019; ZHANG *et al.*, 2023; MIAO *et al.*, 2023; SUN *et al.*, 2019; ZENG *et al.*, 2020; DAN *et al.* 2022; WANG *et al.*, 2023).

Nesse sentido, as lacunas identificadas na literatura que podem ser exploradas se concentram em duas questões principais. Primeiro, há uma falta de parametrização entre os aspectos descritivos dos relatórios de inspeção e o julgamento dos inspetores sobre as condições das OAEs, como a insuficiência estrutural. Além disso, a extração de informações devido ao volume de arquivos é um desafio. Segundo, o uso de métodos de *Machine Learning* pode ajudar a reduzir a subjetividade ao estabelecer padrões para o julgamento dos inspetores. Apesar da complexidade envolvida no tratamento dos dados

das inspeções, essas abordagens sofisticadas ainda são pouco exploradas na gestão e manutenção de infraestruturas.

O campo da inspeção, diagnóstico, monitoramento e manutenção de OAEs está em expansão, com a comunidade científica focada em desenvolver e aperfeiçoar metodologias e ferramentas para a gestão de pontes. Há uma necessidade clara de modelar a relação entre as classificações de inspeção e as características das pontes, assim como a presença ou ausência de insuficiência estrutural. A relevância do tema é evidente, pois propõe uma modelagem explicativa baseada em dados de inspeções das OAEs no Sistema de Gerenciamento de Obras de Artes Especiais (SGO) do DNIT. Este estudo visa aprimorar o entendimento das condições das pontes rodoviárias, conforme os procedimentos da norma DNIT 010/2004-PRO.

1.5 HIPÓTESE

A conjectura do estudo baseia-se: na hipótese de que o julgamento de insuficiência estrutural da ponte pode ser menos subjetivo, a partir da verificação da possível relação entre as características observadas em campo e registradas nos relatórios de inspeções com o julgamento/parecer do inspetor acerca do seu estado de condição geral.

1.6 OBJETIVOS

1.6.1 Objetivo geral:

Propor uma modelagem numérico explicativa para a avaliação do estado de condição das OAEs, na intenção de estabelecer mecanismos quantitativos que minimizem o teor de subjetividade para o tratamento estatísticos dos dados oriundos de inspeções visuais.

1.6.2 Objetivos específicos:

- Caracterizar as OAEs contidas no SGO/DNIT;
- Organizar um banco de dados próprio e sistematizado com informações catalogadas do SGO/DNIT;

- Analisar os principais métodos usados em estudos que verificam o estado de condição das OAEs, expondo as suas vantagens e limitações;
- Realizar estudos de sensibilidades com os dados que compõe o modelo;
- Estabelecer relações de causa/correlação entre as variáveis que compõe o modelo;
- Gerar cenários futuros para os estados de condição das OAEs

1.7 DELIMITAÇÃO E LIMITAÇÃO DO ESTUDO

Neste trabalho apesar de ser realizada uma caracterização das pontes analisadas, o foco principal é na avaliação de insuficiência estrutural a partir do compilado de informações dos relatórios de inspeção. No estudo serão consideradas apenas as estruturas do estado da Paraíba, uma vez que o acesso ao banco de dados do SGO ocorreu de maneira tardia, inviabilizando em termos logísticos a catalogação de um número maior de pontes para o estudo.

1.8 ORGANIZAÇÃO DO DOCUMENTO DE TESE

A tese foi organizada por capítulos, o primeiro com a introdução que discute desde a importância da pesquisa até os objetivos. No segundo, temos a revisão bibliográfica, este traça um panorama geral da produção científica, bem como os fundamentos teóricos envolvidos na tese. O terceiro faz menção aos materiais e métodos utilizados para o desenvolvimento do referido trabalho. O quarto discute os resultados obtidos. No quinto, temos o fechamento do trabalho com as conclusões obtidas e recomendações para futuras abordagens, a partir dessa pesquisa.

2. REVISÃO BIBLIOGRÁFICA

O desenvolvimento das atividades propostas neste trabalho foi embasado na pesquisa bibliográfica, que incluiu um levantamento organizado por procedência e abrangeu tanto fontes científicas — como artigos, dissertações e teses — quanto fontes de divulgação de ideias, como livros, revistas, bases de dados e anais de congressos. Esse processo possibilitou uma visão holística do tema, proporcionando um direcionamento mais preciso para a investigação das práticas nacionais e internacionais de inspeção e gestão de pontes.


Desse modo, neste capítulo apresenta-se o aporte teórico que direcionou a pesquisa, a partir de um levantamento no campo da gerência de infraestruturas, com foco em pontes. Esse levantamento serviu como base para as discussões desenvolvidas ao longo da tese. O capítulo está estruturado em seções: de início apresenta-se um estudo bibliométrico realizado em diferentes bases de dados; e depois destacam-se abordagens relevantes para o tema, explorando desde os aspectos mais fundamentais — como inspeção, normatização e sistemas de gerenciamento — até questões mais complexas, como a classificação do estado de condição, abordagens para avaliação da deterioração, e o controle e garantia da qualidade dos dados de infraestrutura.

2.1 LEVANTAMENTO BIBLIOMÉTRICO

Com o intuito de mapear o estado atual do conhecimento, para então selecionar os trabalhos mais pertinentes a este estudo, realizou-se uma busca bibliográfica considerando, a priori, a sintaxe de busca: “*Bridge Management*” AND “*Deterioration model*”. Estas palavras foram definidas como o critério principal para abordar o escopo conceitual temático inicial desta pesquisa. Para isso utilizaram-se as plataformas *Science Direct*, *Scopus*, e *Web of Science*, através das quais um total de 183 artigos relacionados à temática de gerenciamento de infraestruturas, em sua maioria relacionados à manutenção de pontes, foram encontrados. Neste acervo foram identificados, principalmente, artigos de periódicos e de anais de conferências internacionais.

Na Figura 2 é possível verificar o número de publicações encontradas por ano.

Figura 2 - Número de publicações por ano e base de dados (busca geral)




Fonte: Autora (2024)

Na Figura 2 é possível identificar que, dentre as bases consultadas, a *Scopus* foi a que resultou no maior número de publicações, com um total de 141, seguida pela *Web of Science* com 35 e por fim, pela *Science Direct*, com 9 trabalhos. Além disso, percebe-se uma tendência de crescimento no número de publicações, cujo pico foi identificado no ano de 2023 na base *Scopus*, com 12 trabalhos encontrados.

Os trabalhos encontrados tratam das mais variadas temáticas dentro do escopo do gerenciamento de pontes e modelos de deterioração dessas estruturas, por isso, para se ter um panorama geral das abordagens, desenvolveu-se uma análise de co-ocorrências de palavras-chave no *software VOSviewer*, como se observa na Figura 3.

Figura 3 - Rede de co-ocorrências de palavras-chave em busca geral.




Fonte: Autora (2024).

Os clusters produzidos através do *VOSviewer* possibilitam uma noção dos temas abordados nas publicações, pois, análises de co-ocorrências de palavras-chave permitem mapear e entender as temáticas relacionadas aos objetos de estudo de um pesquisador (INOMATA *et al.*, 2015). No caso específico da Figura 3, identificam-se três *clusters*: o verde, com uma temática mais voltada ao uso de Inteligência Artificial em problemas de tomada de decisão na gerência de pontes; o azul, que aponta o uso de modelos estocásticos, como as Cadeias de Markov na modelagem da deterioração das estruturas; e por fim, o vermelho, que aponta trabalhos que consideram os processos de inspeção na modelagem e gerência das pontes.

Já para identificar as áreas de estudo em que as publicações vêm sendo realizados, desenvolveram-se gráficos a partir de dados das bases *Web of Science* e *Scopus*, que apresentaram maior número de publicações e dados mais completos quando comparadas com a *Science Direct*. A Figura 4 apresenta um gráfico de pizza que ilustra a distribuição percentual de diferentes áreas de estudo a partir da *Web of Science*.

Figura 4 - Percentual de publicação por área de conhecimento (*Web of Science*)




Fonte: Autora (2024)

Na Figura 4, percebe-se que a Engenharia ocupa a maior parcela das publicações, com 59%, seguida pela Tecnologia das Construções com 17%. Outras áreas, como Transportes (7%) e Ciências dos Materiais (5%), têm representações menores. É importante também destacar áreas como a Ciência da Computação e Matemática, dada a importância de estudo que desenvolvam modelos de diferentes naturezas para prever e explicar o comportamento das pontes.

Já a Figura 5, mostra os percentuais de publicações por área de estudo a partir da base *Scopus*.

Figura 5 - Percentual de publicação por área de conhecimento (*Scopus*)




Fonte: Autora (2024)

Quanto à Figura 5, percebe-se que na base Scopus o percentual de publicações na área da engenharia foi ainda maior, 71,5%. Já a segunda posição ficou com a área da ciência da computação, reforçando a relação entre essas áreas, especialmente no que diz respeito à modelagem computacional de pontes (atualmente muito voltada para o uso de inteligência artificial).

Já em relação a distribuição das publicações por países, observam-se as Figuras 6, com dados da *Scopus* e 7, com dados da *Web of Science*.


Figura 6 - Publicações por países (*Scopus*)



Fonte: Autora (2024)

A Figura 6 demonstra que a maior parte das publicações identificadas na base de dados Scopus tem origem na América do Norte, com destaque para os Estados Unidos e Canadá. A Austrália também se sobressai, o que reflete a relevância que esses países atribuem à temática em questão. No caso do Brasil, foram encontradas apenas três publicações, o que chama atenção diante das condições precárias observadas em diversas pontes ao longo do território nacional.

Figura 7 - Publicações por países (*Web of Science*)




Fonte: Autora (2024)

A Figura 7 revela que os dados da *Web of Science* corroboram os resultados observados na Figura 6, referente à base *Scopus*. A maioria das publicações é proveniente dos Estados Unidos, Canadá e Austrália, o que reforça a posição de destaque desses países no contexto da gerência de pontes.

Com base na busca geral, discutida anteriormente, percebeu-se a necessidade de realizar uma busca mais específica, complementando a sintaxe de pesquisa com algumas palavras-chave de interesse deste trabalho. Nesse sentido, uma segunda busca foi realizada considerando a seguinte sintaxe de busca: “*bridge management*” AND “*deterioration model*” AND (“*bridge inspection*” OR “*condition assessment*” OR “*inspection reports*” OR “*visual inspection*”). A busca retornou um total de 67 publicações. A distribuição de publicações ao longo dos anos, de acordo com as bases de dados *Scopus*, *Science Direct* e *Web of Science* pode ser observada na Figura 8.

Figura 8 - Número de publicações por ano e base de dados (busca específica)




Fonte: Autora (2024)

A Figura 8 mostra que a maioria das publicações está registrada na base Scopus, indicada pelas barras azuis, com uma tendência de aumento gradual no número de publicações ao longo do tempo, conforme a linha de tendência pontilhada sugere. Há picos notáveis em 2011 e 2023, evidenciando anos de maior produtividade científica.

Em contrapartida, as publicações em *Science Direct* (barras laranja) e *Web of Science* (barras cinza) são significativamente menores, e essas bases começam a registrar publicações apenas a partir de 2018. Isso demonstra que, embora a *Scopus* seja a base com maior número de publicações sobre o tema, as outras bases também têm registrado contribuições nos últimos anos.

Similarmente ao que foi apresentado anteriormente para a busca geral, elaborou-se no *VOSviewer* uma análise de co-ocorrências de palavras-chave, considerando um mínimo de 10 co-ocorrências nos artigos da busca mais específica. O resultado pode ser observado na rede da Figura 9.

Figura 9 - Rede de co-ocorrências de palavras-chave em busca específica.



Fonte: Autora (2024)

A rede da Figura 9 mostra que o cluster vermelho é o mais central. Este cluster indica, através de palavras como "deterioration" (deterioração), "inspection" (inspeção), "bridge inspection" (inspeção de pontes), "maintenance" (manutenção), e "life cycle" (ciclo de vida), a forte interconexão entre a deterioração estrutural de pontes e as práticas de inspeção e manutenção, essenciais para garantir a durabilidade e segurança ao longo do ciclo de vida da infraestrutura.

Já no menor *Cluster*, em azul percebem-se poucas palavras, com destaque para o termo "Markov processes" (processos de Markov), que indicam a utilização de modelos probabilísticos para prever a deterioração de pontes ao longo do tempo.

Por último, o cluster verde dá indícios de trabalhos focados na modelagem da deterioração e ferramentas de gestão usadas para monitorar e avaliar as condições das pontes. Palavras como "condition assessments" (avaliações de condição) e "nondestructive examination" (exame não destrutivo) sugerem um enfoque em métodos que considerem as inspeções na modelagem. Um exemplo é o trabalho de Wijesuriya e

Tennant (2022) que desenvolveram uma modelagem estatística para priorização de pontes que necessitem de manutenção, a partir dos dados de inspeções das estruturas.

2.2 INSPEÇÕES REALIZADAS EM PONTES

De acordo com a DNIT 010/2004 – PRO, as inspeções em pontes visam a coleta de elementos, de projeto e de construção, o exame da estrutura, a elaboração de relatórios, a avaliação do estado da obra e as recomendações de atividades específicas, tais como manutenção, recuperação, reforço ou reabilitação para cada situação encontrada. As agências de transporte na maioria dos países inspecionam as condições e a segurança das pontes, de acordo com seus próprios manuais de inspeção.

A China determina três tipos de inspeção em ponte: rotineira, periódica e especial. A inspeção de rotina é visual realizada todos os meses. As inspeções periódicas estão programadas e executadas uma vez em três anos. As inspeções especiais ocorrem devido alguma solicitação importante, por exemplo, alteração do tráfego, abalos sísmicos, entre outros fatores ambientais. O *Manual for China Bridge Management System* sugere que o monitoramento contínuo de pontes seja realizado usando a tecnologia de detecção para medir registros das características da ponte sob condições de tráfego. Além disso, as inspeções de pontes são realizadas dependendo da importância das pontes (MOHURD, 2003).

O Japão define apenas a inspeção de rotina da ponte. De acordo com o protocolo do *Regular Inspection Procedure for Road Bridge* (2014), a inspeção inicial deve ser realizada com menos de 2 anos depois de aberta ao público e à inspeção de rotina é realizado a cada 5 anos (MLIT, 2014). Esse protocolo não define nenhuma inspeção executada periodicamente, exceto a inspeção de rotina da ponte. No entanto, são necessárias inspeções detalhadas adicionais, dependendo dos tipos de deterioração, gravidade e extensão (MLIT, 2014).

Na Coreia do Sul, o *Guideline of safety inspection and in-depth safety inspection for structures* define uma inspeção de rotina a ser realizada a cada 6 meses, outras inspeções, como inspeções detalhadas, emergenciais e de segurança aprofundada, podem ser agendadas. Na Tabela 2 estão descritas as inspeções de pontes realizadas na Coreia do Sul.

Tabela 2 - Inspeção de pontes na Coréia do Sul

INSPEÇÃO	DESCRIÇÃO	INTERVALO
Rotina	•Primeira inspeção. Parte do inventário da ponte, onde fornece todas as inspeções subseqüentes.	6 meses
Aprofundada	•Inspeção que depende dos resultados obtidos na inspeção de rotina.	1-3anos
Emergencial	•Inspeção solicitada pelo programa de inspeção, por conta de (terremotos, inundações, etc).	Em casos especiais
Segurança aprofundada	•Inspeção que depende dos resultados obtidos nas inspeções aprofundadas ou inspeções especiais.	4-6 anos

Fonte: (MOLIT, 2012c)

As inspeções realizadas na Coréia do Sul, descritas na Tabela 2 são de maneira geral, bem articuladas entre si, pois apresentam padrões e periodicidades bem definidos. Vale ressaltar, que os referidos procedimentos podem ser mais detalhados no *Guidelines and Commentary for Safety Inspection and In-depth Safety Inspection for Structures-Bridge* (2013).

Nos EUA, o manual do AASHTO define as inspeções, os gestores estabelecerem seus próprios níveis de frequência e o tipo de estrutura são definidos pela AASHTO e pela FHWA. O *National Bridge Inspection Standards* (NBIS) foi criado para elaborar um programa nacional para inspeção de pontes, este considera: procedimentos de inspeção; periodicidade das inspeções; capacitação da mão de obra; relatórios de inspeções; inventário da manutenção das pontes e a importância do *Bridge Maintenance System* (BMS). A Tabela 3, lista os tipos de inspeções dos EUA e as suas descrições.

Tabela 3 - Tipos e intervalos de inspeções nos EUA

INSPEÇÃO	DESCRIÇÃO	INTERVALO
Inicial	• Primeira inspeção. Parte do inventário da ponte, onde fornece todas as inspeções subseqüentes.	Na abertura da ponte
Rotina (periódica)	• Inspeção a partir de observações e/ou medições das condições físicas e funcionais da ponte.	≤ 24 meses
Dano em profundidade	•Inspeção não programada para avaliação estrutural. Uma inspeção fechada para identificar deficiências não facilmente detectáveis.	Vários*
Fratura crítica	• inspeção de membro crítico ou componentes que sugerem avaliações não destrutivas.	≤ 24 meses

Especial Subaquática	• Inspeção da parte subaquática de uma subestrutura da ponte e do canal circundante.	≤60 meses
	• Inspeção agendada, usada para monitorar uma deficiência conhecida ou suspeita.	Vários*

Fonte: (FHWA, 2011)

* **Vários:** Os DOTs podem determinar intervalos para danos, inspeção detalhada e especial.

As inspeções realizadas no EUA, e descritas sucintamente na Tabela 3 fornecem informações sobre a gravidades dos danos encontrados nos elementos, mas não identificam ou quantificam a sua extensão. Vale ressaltar, que os componentes principais verificados nas inspeções são: plataforma, superestrutura e subestrutura (LIAO *et al.*, 2017).

De acordo com a *UK's Highways Agency*, no Reino Unido existem cinco tipos de inspeções para pontes e podem ser usados em combinação, dependendo das necessidades de inspeção. Na Tabela 4, têm-se os tipos de inspeções realizadas no Reino Unido.

Tabela 4 - Tipos de inspeção de ponte no Reino Unido

INSPEÇÃO	DESCRIÇÃO
Aceitação	Executada para novas pontes, pontes recentemente reparadas e novo início de um novo contrato de manutenção
Superficial	As verificações de defeitos pendentes que representam um risco para a segurança são destacadas e medidas são tomadas imediatamente para corrigi-los
Geral	Aplica-se a elementos de ponte que são facilmente acessíveis
Principal	Todos os elementos da ponte, incluindo aqueles de difícil acesso. Isso às vezes pode exigir máquinas ou ferramentas de acesso especializado
Especial	Investigação detalhada de um determinado componente da ponte. As pontes que foram reforçadas com placas coladas a elas também requerem inspeções especiais

Fonte: (Liao *et al.*, 2017)

As informações vistas na Tabela 4 referem-se aos requisitos estabelecidos no *Design Manual for Roads and Bridges* (BD 63/07) (*HIGHWAYS AGENCY*, 2007). A metodologia de inspeção visual no Reino Unido baseia-se principalmente em procedimentos que verificam a extensão e severidade dos danos encontrados nas pontes. A gravidade é definida como o grau de dano, enquanto a extensão é uma medida do comprimento, área ou número de defeitos do elemento de ponte (LIAO *et al.*, 2017).

A Alemanha realiza inspeções de pontes em dois níveis, principal e secundário. O principal é do tipo *arms-length*, ou seja, todos os elementos da ponte são verificados. O secundário é feito três anos após o teste principal. Na Tabela 5, tem-se os tipos de inspeção realizadas na Alemanha.

Tabela 5 - Inspeções realizadas nas pontes da Alemanha	
INSPEÇÃO	DESCRIÇÃO
Teste Principal	Inspeção de todos os componentes; usa equipamento de acesso e inclui inspeção subaquática
Aceitação	Teste principal
Garantia	Teste principal
Teste Menor	Verificação do estado atual de danos e defeitos conhecidos
Superficial	Inspeção superficial para segurança
Ad hoc	Após eventos significativos, como tempestades, inundações, etc.
Sistemas	Inspeção de sistemas elétricos ou mecânicos

Fonte: Liao *et al.* (2017)

Na Dinamarca, o Departamento responsável pelas rodovias, *Danish Road Directorate*, realiza oito tipos de inspeções de pontes. Na Tabela 6, tem-se os tipos de inspeções realizadas.

Tabela 6 - Tipos de inspeções realizadas na Dinamarca	
INSPEÇÃO	DESCRIÇÃO
Inventário	Coleta dados de ponte e condições de linha de base
Diariamente*	Exame rápido observando falha, dano, detritos, etc.*(Não é uma parte formal do Programa de Inspeção de ponte)
Rotina - estendida	Planejamento e verificação de rotina de limpeza e manutenção
Relatórios de usuários	Relatórios de: danos por impacto, vandalismo, detritos na ponte ou estrada e danos por erosão
Principal	Inspeção visual completa e sistemática de todos os componentes
Especial	Coleta de informações mais detalhadas para decisões sobre ações de manutenção
Inspeção Econômica Especial	Preparação para grande projeto de reparo de ponte

Inspeção Especial	Técnica	Investigações de danos, investigações especiais, avaliações de capacidade de carga
--------------------------	----------------	--

Fonte: Liao *et al.* 2017

Para as inspeções vistas na Tabela 6, as recomendações sobre os intervalos dependem da idade, Volume Diário Médio (VDM), localização, condições existentes e características especiais da ponte. Em cada defeito relatado, o inspetor irá recomendar um esquema de reparo, seu ano de aplicação, e também estimar os custos para ações de reparo (Liao *et al.*, 2017).

Na África do Sul a inspeção de pontes é feita pela *South Africa National Roads Agency Limited* (SANRAL) em estradas nacionais, 9 (nove) departamentos provinciais de transporte para pontes em estradas provinciais e agências de transporte municipais para pontes municipais. A prática de manutenção sul-africana inclui cinco tipos de inspeções, vistas na Tabela 7.

Tabela 7 - Inspeções de pontes na África do Sul

INSPEÇÃO	DESCRIÇÃO
Monitoramento	Uma verificação rápida dos novos defeitos e do estado dos defeitos conhecidos anteriormente. Essa não produz classificação de condição
Principal	Um exame completo e registro de todos os defeitos
Verificação	São realizadas anualmente a fim de verificar a precisão dos dados
Nível de projeto	Inspeção para coletar informações para documentos contratuais
Aceitação	Inspeção de trabalho durante e após um contrato

Fonte: Liao *et al.* (2017)

Os defeitos encontrados a partir das inspeções descritas na Tabela 7 são classificados quanto ao seu grau, extensão, relevância e urgência. Assim, além de identificar defeitos, há uma avaliação para priorizar a sua importância relativa para a integridade estrutural da ponte. É importante dizer que as inspeções não estão diretamente associadas apenas aos elementos da ponte em si, mas aos danos relatados. O método de avaliação e as inspeções visuais adotadas para as pontes da África do Sul foram desenvolvidas em conjunto, pela *Join Engineering Consultants* e pela *South African CSIR Company* (LIAO *et al.*, 2017).

Na Suécia, a *Swedish Road Administration* (SRA) desenvolve quatro níveis de inspeções de rotina: Regular, Superficial, Geral e Principal. Na Tabela 8 estão descritas as inspeções realizadas na Suécia.

Tabela 8 - Tipos de inspeções da Suécia

INSPEÇÃO	FREQUÊNCIA
Regular	Visita rápida para detectar novas condições significativas
Superficial	Verifique se os requisitos de manutenção foram atendidos
Geral	Acompanhamento dos danos vistos na última inspeção
Principal	Inspeção visual de todos os componentes
Especial	Investigação adicional de defeito ou deterioração

Fonte: Liao *et al.* (2017)

A Suécia não possui regulamentações para as inspeções de pontes, portanto, os trabalhos realizados pela SRA incluem gerenciamento estratégico, planejamento de projetos, especificações para obras de pontes, aquisição de obras de pontes e supervisão de obras. A SRA executa cerca de metade de todas as inspeções da ponte, com outras feitas por consultores (LIAO *et al.*, 2017).

No Brasil, existem seis tipos de inspeções que são: cadastral, rotineira, especial, subaquática, extraordinária e em caso específico, a intermediária. Na Tabela 9 estão sintetizados os tipos de inspeções realizadas no Brasil e suas especificidades.

Tabela 9 - Frequência das inspeções do Brasil

TIPO DE INSPEÇÃO	FREQUÊNCIA
Inspeção Cadastral	Primeira inspeção. Feita logo após a construção, ou quando se inclui a obra no SGO, ou se sofrer alterações estruturais
Inspeção Rotineira	A cada dois anos
Inspeção Especial	A cada cinco anos
Inspeção Subaquática	Considerada como parte integrante da inspeção especial.
Inspeção Extraordinária	Quando ocorrer um grave acidente na obra
Inspeção Intermediária	Para certas obras, quando recomendado por inspeções anteriores

Fonte: DNIT (2016)

As inspeções realizadas no Brasil, descritas na Tabela 9, seguem a Norma DNIT 010/2004-PRO, esta estabelece conceitos, tipos de inspeções, as exigências necessárias para qualificação dos inspetores, além da frequência mínima das vistorias. Os critérios

estabelecidos na NBR 9452 (ABNT, 2016), também orientam quanto as inspeções, esta, além dos conceitos e orientações comuns a norma do DNIT, introduziu uma maior variabilidade, ao incluir parâmetros estruturais, funcionais e de durabilidade. O manual de Manutenção de Obras de Artes Especiais – OAEs, DNIT (2016), estabelece os tipos de manutenção e a suas respectivas periodicidades, de maneira detalhada trata dos danos mais recorrentes nos elementos de ponte e as técnicas de recuperação adotadas, entre outros assuntos.

2.3 ALGUNS MANUAIS, GUIAS E NORMAS UTILIZADAS PARA INSPEÇÃO

As atividades de inspeção de pontes são desenvolvidas a partir das especificações descritas em documentos, tais como manuais, guias e normas, estes descrevem minuciosamente os procedimentos que devem ser realizados nas OAEs. Com base nos manuais de inspeção de pontes de alguns países, existem três níveis administrativos: (1) empresas controladas pelo governo; (2) agências governamentais e (3) empresas privadas.

Na Coreia uma empresa controlada pelo governo faz as inspeções com receitas de pedágio e fundos do governo. Na China e nos EUA, as agências governamentais (MOT na China, FHWA e os DOTs nos EUA) gerenciam as pontes com fundos locais e nacionais. As agências de transporte no Japão (NEXCO Central, NEXCO Leste, NEXCO Oeste) são empresas privadas que gerenciam as pontes com receita de pedágio.

No Brasil, as pontes podem estar localizadas em rodovias sob jurisdição federal, estadual ou municipal, assim sob responsabilidade do DNIT, dos Departamentos de Estradas de Rodagem (DER) e Secretarias de Infraestrutura, respectivamente. O gerenciamento das atividades de manutenção em pontes é realizado pelo Estado ou sob uma parceria público privada, no entanto o órgão responsável pelas parcerias é o DNIT. Compete aos órgãos responsáveis manter cadastro atualizado de todas as estruturas sob sua jurisdição administrativa. Vale ressaltar que ao Estado e aos municípios compete a administração de suas OAEs, detendo o poder de utilização e o dever de manutenção destas. Na Tabela 10 podem ser vistos manuais, guias e normas que regem as atividades inerentes ao gerenciamento de OAEs de alguns países.

Tabela 10 - Manuais, guias e normas para a manutenção em pontes

PAÍS	PUBLICADO	DOCUMENTO
China	<i>Ministry of Housing and Urban-Rural Development of the People's Republic of China (MOHURD).</i>	• <i>Technical Code of Maintenance for City Bridge, CJJ99–2003, 2003.</i> • <i>The Guidance for Road and Bridge Maintenance, 2007.</i> • <i>Manual for China Bridge Management System v. WEB20 (MCBMS), 2007.</i>
	<i>The Ministry of Transport of the People's of China (MOT).</i>	• <i>Standards for Technical Condition Evaluation of Highway Bridges, JTG /T-H21–2011, 2011.</i> • <i>Specifications for Inspection and Evaluation of Load-bearing Capacity of Highway Bridges, JTG /T-J21–2011.</i>
Japão	<i>Ministry of Land, Infrastructure, Transport and Tourism (MLIT).</i>	• <i>Manual for Bridge Periodic Inspection, 2014.</i>
Coréia	<i>Ministry of Land, Infrastructure, and Transport (MOLIT).</i>	• <i>Guidelines and Commentary for Safety Inspection In-depth Safety Inspection for Structures-Bridge, 2013.</i>
Alemanh a	<i>Der Bundesminister für Verkehr Abteigung Strabenbau</i>	• <i>Richtlinie zur Tragfähigkeitseinstufung bestehender Straßenbrücken der neuen Bundesländer in Lastklassen nach DIN 1072, 1992.</i>
	<i>Bundesministerium für Verkehr, Bau und Stadtentwicklung</i>	• <i>Bauwerksprüfung nach DIN 1076 Bedeutung, Organisation, Kosten, 2013</i>
França	<i>Club d'echange d'experiences sur les routes departementales Gestion</i>	• <i>Gestion Des Ouvrages d'art Guide Methodologique, 1990</i>
	<i>Service d'Études techniques des routes et autoroutes</i>	• <i>Gestion des ouvrages d'art – A l'usage des départements et autres collectivités locales – Guide méthodologique, 2006</i>
Irlanda	<i>Transport Infrastructure Ireland</i>	• <i>EIRSPAN Bridge Management System Principal Inspection Manual AM-STR-06054</i>
		• <i>EIRSPAN Bridge Management System Principal Inspection Manual AM-STR-06055</i>
Noruega	<i>Public Roads Administration, Norwegian</i>	• <i>Norwegian Public Roads Administration Handbook for Bridge Inspections, 2005</i>
Reino Unido	<i>Highways England Transport Scotland Còmhdhail Alba</i>	• <i>Highway Structures & Bridges Inspection & Assessment. CS 450 Inspection of highway structures.</i>
	<i>Llywodraeth Cymru Welsh Government</i>	• <i>Highway Structures & Bridges Inspection & Assessment. CS 454 Assessment of highway bridges and structures</i>
	<i>Department for Infrastructure an Roinn Bonneagair</i>	• <i>Design Manual for Roads and Bridges. Highway structures: Inspection and Maintenance. BD 63/07 Volume 3, Section 1, Part 4. 2007</i>
	<i>Transport and Road Research Laboratory TRL Limited</i>	• <i>A Guide to Bridge Inspection and Data Systems for District Engineers, 1988</i> • <i>Bridge Inspector's Handbook, 2004</i>
	<i>American Association of State Highway and Transportation Officials (AASHTO).</i>	• <i>LRFD Bridge Design Specifications Customary U.S. Units. 2012</i> • <i>Guide Manual for Bridge Element Inspection, 2011</i> • <i>Manual for Bridge Element Inspection, 2019</i>

Federal Highway Administration (FHWA).		• <i>Bridge Inspector's Reference Manual</i>, FHWA-NHI-12-049, 2012. • <i>Recording and Coding Guide for the Structure Inventory and Appraisal of the Nation's Bridge</i>, FHWA-PD-96-001, 1995. • <i>Underwater Bridge Inspection Manual</i>, FHWA-NHI-10-027, Pre-Publication Edition, 2010 • <i>Underwater Bridge Repair, Rehabilitation, and Countermeasures Manual</i>, FHWA-NHI-10-029, Pre-Publication Edition, 2010
	Canadá	• <i>Field Inspection Guide</i>, 2008 • <i>Ontario Structure Inspection Manual (OSIM)</i>, 2008
	Brasil	NORMA DNIT 010/2004 - PRO. <i>Inspeções em pontes e viadutos de concreto armado e protendido – Procedimento</i> . Instituto de Pesquisas Rodoviárias. DNIT. Ministério dos Transportes. Brasil. DNIT. <i>Manual de Manutenção de Obras de Artes Especiais – OAEs</i> . Brasília. 2016.
		• ABNT (2016) <i>NBR 9452. Vistorias de Pontes e Viadutos de Concreto</i>. Associação Brasileira de Normas Técnicas. 3. ed. Rio de Janeiro.

Fonte: Autora (2020)

É importante destacar a inspeção como a etapa inicial do gerenciamento do comportamento das OAEs, no entanto, está sozinha não teria como determinar de forma eficiente a real condição da estrutura, por conta do alto grau de subjetividade envolvida nas avaliações dos inspetores em campo. Diante da importância da estruturação documental para que de fato haja uma boa investigação nas pontes, algumas pesquisas têm se debruçado sobre a avaliação de padrões, diretrizes e melhores práticas disponíveis no que concerne as inspeções realizadas em diferentes países do mundo, para isso consultando-se, avaliando-se e comparando-se alguns manuais e normas.

Nos estudos proposto por Turksezer *et al.* (2021) e Lacovino *et al.* (2022), cinco indicadores são utilizados para comparar diferentes políticas de inspeções, que são designados como 5Ws, a partir da sua letra inicial comum, e são definidos como: WHEN (frequência de inspeção), WHICH (métodos de inspeção), WHO (pessoal de inspeção e nível de treinamento), WHAT (inspeção resultado) e WERE (elementos). Esses indicadores têm sido usado para descrever e quantificar diferentes aspectos da inspeção, tais como, qualidade dos dados, nomeadamente, correção relacionada com a qualificação dos inspetores, correção relacionada com as ferramentas utilizadas para

realizar inspeção, pontualidade relacionada à frequência da inspeção, integridade vinculada aos componentes inspecionados (ONDE) e nível de processamento de dados.

2.4 SISTEMAS DE GERÊNCIA DE PONTES

Segundo López (2020) um sistema de gerência de pontes auxilia na seleção da atividade correta, na ponte certa, no tempo adequado e com custo justo. Os objetivos de um sistema de gerência de pontes devem ser: garantir a segurança; conservar o patrimônio a longo prazo e a custos apropriados; e assegurar um nível de serviço adequado. Em relação à abordagem, Venezuela *et al.* (2010) identificam duas gerações de sistemas: uma antiga focada nos inventários, inspeções e na avaliação das pontes, e outra recente focada em recursos matemáticos e estatísticos.

Almeida (2013) categorizou os sistemas de gerência de pontes de acordo com três grupos: o objeto de análise, tipo de avaliação e tipo de apoio à decisão. O apoio à decisão ainda foi subcategorizado em três grupos, isto é, de acordo com o tipo de critérios ponderados, processamento da informação e ações planejadas. Na Tabela 11, temos as categorias e subcategorias da gerência de pontes segundo o autor anteriormente citado.

Tabela 11 - Categorias de gerência de pontes

CATEGORIA	SUBCATEGORIA	TIPOS
Objeto principal da análise		Rede
		Parque de pontes
		Ponte
		Elementos de ponte
Tipo de Avaliação		Estado de condição
		Avaliação de segurança
		Avaliação de risco
Apoio a decisão	Critérios ponderados	Desempenho estrutural
		Custo
		Outros (funcionalidade, ambiente, etc.)
	Processo da inf.	Análise multicritério


Em relação ao objeto principal da análise, Almeida (2013) diz que um sistema de gerência de pontes analisa em termos de rede viária, em um conjunto de pontes ou individualmente, considerando cada um de seus componentes (tabuleiro, superestrutura, subestrutura). Essa discussão relaciona-se com o tipo de filosofia de gestão, segundo López (2020), existem duas filosofias de abordagens: *top-down e bottom-up*. A primeira atua em serviços a toda rede. Já a segunda atua estabelecendo ações em pontes individualmente.

Em relação ao tipo de avaliação, a categorização ocorre de acordo com o tipo de indicador de desempenho a ser utilizado: avaliação do estado de condição, avaliação de segurança e avaliação de risco. Na avaliação de estado de condição, são consideradas as inspeções visuais e a indicação de desempenho ocorre a nível generalizado. A avaliação de segurança remete a um processo de inspeção mais detalhado, com procedimentos que geram diagnósticos mais detalhados. A avaliação de risco analisa a probabilidade de falha da estrutura (ALMEIDA, 2013).

Os critérios em um sistema de gerência de pontes podem englobar indicadores de desempenho relacionados à condição das pontes e, conjuntamente, englobar indicadores relacionados à funcionalidade dessas estruturas. Além desses grupos de critérios, pode-se considerar indicadores relacionados ao impacto ambiental e aos custos. Além dos tipos de critérios, destaca-se ainda os mecanismos de processamento das informações de um sistema de dados. Tais procedimentos podem ocorrer por meio de uma análise multicritério ou por meio de um procedimento de otimização que visa selecionar a estratégia ótima a ser adotada (ALMEIDA, 2013).

Segundo Moscoso (2017) é possível definir três componentes de um sistema de gerência de pontes, tais como banco de dados, análise de dados e apoio à decisão. Na Figura 10 tem-se um esquema simplificado dos componentes de um Sistema de gerência de pontes.

Figura 10 - Componentes básicos do SGO



Fonte: Moscoso (2017)

O módulo de banco de dados engloba as informações cadastrais, de inventário, histórico de manutenção, as avaliações de condição, demais dados de inspeções, dados de tráfego, dados de custo etc. O módulo de análise de dados contém as estruturas responsáveis por processar os dados do banco de dados, neste pode conter modelos de deterioração, modelos de custo, modelos de determinação de índices de priorização ou, apenas, determinar o índice que represente o estado de condição atual. O módulo de apoio à decisão gera informações úteis aos gestores para que a decisão a ser tomada seja a mais adequada possível frente às necessidades e limitações da rede de pontes.

Ressalta-se, ainda, a importância do contínuo processo de realimentação do banco de dados como fator importante na constante evolução de qualidade do sistema de gerência. López (2020), destaca que, para que um sistema de gerência de pontes alcance seus objetivos, são necessários procedimentos sistematizados de coleta, processamento e atualização dos dados.

De maneira geral, os sistemas de gerência de pontes determinam as atividades a serem realizadas para um bom nível de serviço. Essas atividades podem ser detalhadas, isto é, tarefas que devem ser realizadas a nível de elemento de ponte, ou não, indicando apenas aquelas pontes que deverão passar por Manutenção, Reabilitação ou Substituição (ALMEIDA, 2013). Nos parágrafos a seguir destacam-se alguns dos sistemas de gerência de pontes do mundo.

O Sistema PONTIS é um sistema integral de gerência de pontes oriundo do EUA onde são armazenadas informações das inspeções nas OAEs, para serem modeladas e analisadas, buscando um embasamento para o desenvolvimento de projetos,

orçamentação e desenvolvimento de programas. O *software* PONTIS usa modelos probabilísticos, especificamente modelos Markovianos, para realizar otimizações. Este sistema está configurado nas etapas a seguir: módulo de inventário, consta as informações e características de cada OAEs; módulo de inspeção, usado para manter informações de inventário e inspeção sobre as estruturas; módulo de planejamento de projetos, permite visualizar as necessidades de cada estrutura e analisar a estrutura futura para diferentes suposições sobre o trabalho a ser feito; módulo de programação, usado para definir políticas, padrões de melhoria de estrutura, executar simulações de cenários alternativos de programas plurianuais e módulo de preservação, usado para desenvolver e executar modelos que permitam determinar políticas de preservação (GUTKOWSKI; ARENELLA, 1998).

O BRIDGIT foi desenvolvido no âmbito do Programa Cooperativo de Pesquisa Rodoviária (*National Cooperative Highway Research Program - NCHRP*), patrocinado pela AASHTO dos EUA e conta com os seguintes módulos: módulo de inventário, que permite às agências criar um número ilimitado de itens de dados para cada OAEs, bem como para vãos individuais, pilares, juntas e rolamentos de uma ponte; módulo de inspeção, que permite que as agências visualizem ou editem informações de inspeção para cada elemento da ponte ou do sistema de proteção; módulo de manutenção, reabilitação e substituição, permite às agências planejar, agendar e monitorar programas de trabalho plurianuais; módulo de modelos, permite visualizar ou modificar os vários modelos e tabelas a serem usados na análise de otimização; módulo de análises, produz planos de trabalho otimizados a partir do módulo de inventário, módulo de inspeção e o módulo de modelos, para toda ou parte da população das OAEs, em um horizonte de análise definido (HAWK, 1999).

O Sistema GOA, está atualmente implantado em Portugal, é constituído por módulos que permitem a instalação de um sistema básico, passível de ampliação por módulos adicionais no futuro. O Sistema prevê as atividades de: inventários; inspeção principal; classificação por prioridade e otimização; lista de preços (preços unitários referentes aos serviços de recuperação); estimativas de custos e manutenção. Também em Portugal, na ponte Vasco da Gama, encontra-se implantado um dos sistemas de manutenção estrutural computadorizado mais avançados da atualidade, o SCANPRINT (VITÓRIO, 2002).

BRIME é um projeto desenvolvido pelo Reino Unido, França, Alemanha, Noruega, Eslovênia e Espanha. Tem os seguintes módulos: módulo de revisões para

inspeção, onde os elementos das OAEs são definidos especificamente, e a condição da estrutura é determinada pela gravidade e extensão dos danos observados; separadamente estão o módulo de inventário e Inspeção, ferramenta para inserir, visualizar, editar e relatar as informações da inspeção realizada; módulo organização e implantação do banco de dados, onde é usado um banco de dados para manter o inventário das inspeções; módulo para o processo de tomada de decisão, onde as decisões de manutenção e reparação são feitas nos escritórios regionais a partir do funcionamento operacional. O *software Oracle* é utilizado, nele são atualizados periodicamente os dados e também são replicados em um banco de dados do *Microsoft SQL Server* (ELLIS *et al.*, 2008).

O DANBRO é o sistema de gerenciamento de Obras de Arte da Dinamarca. É usado na gestão, contratos e orçamentos a nível nacional. O sistema DANBRO oferece dois módulos: módulo de registro, apresenta os acordos e obrigações ligados a cada ponte e módulo de preços, onde as informações sobre os preços do contratante ficam disponíveis (HENRIKSEN, 1999).

O SGO é o sistema de gerenciamento de obras de arte especiais do Brasil. Foi desenvolvido pelo DNIT, que mantém controle sobre as OAEs através de inspeções, onde o mesmo está na sua terceira versão, contando com funções que auxiliam na identificação das necessidades das estruturas e no estabelecimento das prioridades. O sistema é composto de três subferramentas: SGO *Mobile*, SGO *Inspetor* e SGO *Web*. A primeira reúne as anotações das vistorias de campo. A segunda permite que o inspetor insira dados da vistoria (como fotos, croquis, vídeos) no sistema, por meio de um aplicativo disponível em *tablets*. A terceira, o SGO *Web*, disponibiliza os dados na internet.

No Brasil, ligado também a gerência de pontes está o Programa de Reabilitação de Obras de Arte Especiais (PROARTE) que tem por objetivo o atendimento das necessidades de intervenções de restauração, restauração + reforço estrutural e restauração + reforço estrutural + alargamento nas Obras de Arte Especiais da malha rodoviária federal. A metodologia está baseada na definição das intervenções necessárias para a recuperação, reforço e alargamento das OAEs através de diagnóstico de campo, baseado em procedimentos-padrão de cadastro e avaliação (DNIT, 2011). Após a conclusão da avaliação, há a constatação das OAEs com risco de ruptura, sendo assim são imediatamente encaminhadas para que sejam tomadas as providências de intervenções necessárias.

Diante do exposto anteriormente percebe-se, os avanços em termos de gerência de pontes na elaboração dos *Bridge Maintenance Systems* (BMS), bem como o

incremento de ferramentas e critérios que explorem as infraestruturas numa perspectiva cada vez mais holística nestes. Além dos sistemas de gerência de pontes destacados anteriormente, abordam-se outros, bem como os critérios mais utilizados em suas concepções. Na Tabela 12, pode ser visto o cenário mundial em termos dos Sistemas de gerência de pontes de alguns países.

Tabela 12 - Cenário mundial dos Sistemas de Gerência de Pontes

PAÍS	SISTEMA	CRITÉRIOS UTILIZADOS			
		CONDIÇÃO	SEGURANÇA	RISCO	CONFORTO
China	CBMS	✓	✓	✓	
Japão	RPIBMS	✓	✓	✓	
Coréia do Sul	KRBMS	✓		✓	
EUA	PONTIS	✓	✓	✓	✓
	ABMS	✓	✓	✓	✓
	BRIDGIT	✓	✓	✓	✓
Dinamarca	DANBRO	✓	✓	✓	
Portugal	GOA	✓	✓		✓
	SCANPRINT	✓	✓		
Brasil	SGO	✓			
Argentina	SIGMA	✓			
Chile	GRDR	✓		✓	
México	SIPUMEX	✓			✓
Itália	APTBMBS	✓	✓		✓
Polônia	SMOK	✓			✓
	SZOK	✓			✓
Finlândia	FBMS	✓	✓		✓
Irlanda	EIRSPAN	✓	✓		✓
Suécia	BATMAN	✓	✓		✓
Suíça	KUBA-MS	✓	✓		✓
Canadá	OBMS	✓	✓	✓	✓
	QBMS	✓	✓	✓	
Alemanha	GBMS	✓	✓		✓

	SIB- BAUWERKE	✓	✓	✓	✓
França	IQOA	✓	✓	✓	✓
Holanda	DISK	✓	✓		✓
Inglaterra	COSMO	✓	✓		✓
Reino Unido, Eslovênia, Espanha, etc...	BRIME	✓	✓	✓	✓

Fonte: Nietoa (2019), Strauss (2017), Kim (2018), Jeong (2018), Almeida (2013), Oliveira (2019)

Os critérios utilizados na concepção dos *Bridges Maintenance Systems* (BMSs) que estão na Tabela 12 são: conforto, que está relacionado diretamente ao usuário; risco refere-se à possibilidade de falha eminente estrutural ou funcional; segurança relaciona-se aos aspectos de proteção, por exemplo, a presença ou ausência de dispositivos de segurança, tais como guarda-corpo, acostamentos, calçadas, etc., bem como o estado desses itens; condição, que é uma avaliação generalizada do estado de conservação de elementos da ponte. E a partir desse último, destacam-se outros fatores importantes no processo de gerenciamento das pontes, que são os conceitos de vida útil, desempenho e ciclo de vida, estes relacionados a classificação do estado de condição das OAEs.

2.5 CICLO DE VIDA, VIDA ÚTIL, DESEMPENHO E CLASSIFICAÇÕES DO ESTADO DE CONDIÇÃO DAS PONTES

2.5.1 Ciclo de vida

O ciclo de vida das Obras de Arte Especiais (OAEs) é um processo que envolve fatores de planejamento, construção, uso e desativação, estes com vistas ao rigor técnico para garantir durabilidade, segurança e funcionalidade dessas estruturas. Dada a relevância do tema, pesquisas exploram diversos aspectos, desde a integridade estrutural até a sustentabilidade, custos e riscos. Um exemplo é o estudo de Kim Hyusink et al. (2020), que analisou os impactos da manutenção nos custos do ciclo de vida de pontes, utilizando dados do inventário nacional dos EUA para propor o cenário ideal de

manutenção para estruturas de concreto, avaliando alterações na classificação de estabilidade e registros de manutenção.

2.5.2 Vida útil

Em relação à vida útil de OAEs, pode-se dizer que há uma forte influência entre o projeto adequado e a especificação precisa dos materiais, fatores estes que reduzem custos de manutenção e prolongam a durabilidade - que é a capacidade de desempenhar suas funções, ao longo do tempo e sob condições de uso e manutenção especificadas - além da intensidade do tráfego e das cargas móveis, que afetam diretamente o fenômeno da fadiga; Volland *et al.* (2020) classificam a vida útil, como o período de tempo em que a estrutura cumpri a função pretendida dentro dos limites aceitáveis.

Silva (2022) estimou a vida útil de 98 pontes e viadutos em rodovias federais de Pernambuco usando o Método dos Fatores e Análise de Sobrevivência. As OAEs foram agrupadas pelo tipo de material da superestrutura (concreto armado e protendido) com base em inspeções de 2019. Os resultados mostraram que as superestruturas em concreto armado apresentam maior deterioração em comparação às de concreto protendido, com idades médias estimadas de 34 e 55 anos, respectivamente.

Nesse contexto, onde o comportamento da estrutura em uso começará a ser insatisfatório, introduz-se assim, o conceito de desempenho.

2.5.3 Desempenho

As discussões sobre o tema desempenho ficaram ainda mais evidentes a partir da criação, em 2015, do COST ACTION TU 1406, um Programa constituído de 29 países europeus e 6 não localizados na Europa, na intenção de desenvolver e estabelecer planos de controle de qualidade, segurança, manutenção e gestão das pontes rodoviárias, como também padronizar os procedimentos para avaliação de desempenho (MATOS e CASAS, 2018; MATOS, CASAS e FERNANDES, 2016).

Diante do exposto, fica evidente, que o ciclo de vida, a vida útil, a durabilidade e o desempenho nas OAEs (Obras de Artes Especiais), estão intimamente associados e implicam na necessidade do conhecimento e combate da agressividade ambiental e das causas das deficiências estruturais. Por isso, tem-se inegável papel os indicadores de desempenho para a avaliação do estado de condição das pontes rodoviárias.

2.5.4 Classificações do Estado de condição das pontes

O estado de condição ou *Condition Index* (IC) é o indicador de desempenho mais utilizado nos *Bridge Management System* (BMS), ele categoriza a deterioração dos elementos da ponte, faz a comparação da situação atual com a condição construída, é obtido por inspeção visual e pode ser usado para permitir que os tomadores de decisão planejem e agendem o reparo/reabilitação de pontes deterioradas (STRAUSS, 2017). Segundo Nietoa (2019), a classificação do estado de condição de uma ponte é obtida, de maneira geral, por meio de um processo de hierarquia analítica, a partir da avaliação subjetiva realizada por especialistas. A classificação consiste em ponderações que avaliam fatores frequentemente utilizadas para estudos de infraestrutura tais como segurança, serventia, conforto, resiliência, etc.

Diante da importância do IC, a partir deste parágrafo ressaltam-se alguns procedimentos para sua determinação em alguns países. Nos EUA, os Departamentos de Transporte (DOTs) relatam os dados do Inventário Nacional de Pontes (NBI), onde a partir deste são estabelecidos os estados de condições das pontes, que refletem a gama das condições físicas dos principais componentes desta, como a plataforma, superestrutura, subestrutura, bueiro e sub-elementos em uma escala que varia de 0 a 9.

Além do exposto anterior, nos EUA existe uma avaliação do nível de serviço da ponte no sistema de transportes. Os critérios utilizados são: estruturalmente deficiente (SR) e o funcionalmente obsoleto (FO), cada um destes é avaliado por nota que varia entre 0 e 9. A partir do desempenho alcançado, as estruturas são classificadas em SR: avaliação da condição do estrado, superestrutura ou subestrutura menor ou igual a quatro e avaliação estrutural ou adequação da hidrovia menor igual a dois; FO: geometria do convés, altura da rodovia que passa por baixo e largura entre unidades da subestrutura menor ou igual a três e avaliação estrutural ou adequação da hidrovia menor ou igual a três (FHWA, 2011). Na Tabela 13 visualiza-se a escala de avaliação das pontes nos EUA

Tabela 13 - Escala de avaliação do estado de condição de pontes (EUA)		
ESTADO	DESCRIÇÃO	AÇÕES
9	Condição excelente	Manutenção
8	Condição muito boa: sem problemas	Preventiva
7	Condição boa: alguns problemas menores	

6	Condição satisfatória: elementos estruturais mostram deterioração menor	Manutenção Preventiva e/ou Reparos
5	Condições razoáveis: todos os elementos estruturais principais estão sólidos, mas podem ter perda de seção	
4	Condição ruim: avançada perda de seção, deterioração e fragmentação	Reabilitação ou Substituição
3	Condição seria: perda de seção, deterioração e fragmentação. Os componentes estruturais primários estão afetados seriamente. Falhas locais são possíveis. Fissuras de fadiga no aço ou de cisalhamento no concreto podem estar presentes	
2	Condição crítica: avançada deterioração dos elementos estruturais primários. Fissuras de fadiga no aço ou de cisalhamento no concreto podem estar presentes. A ponte pode ter que ser fechada até sejam tomadas medidas corretivas	
1	Condição iminente de falha: grande deterioração ou perda de seção presentes nos componentes estruturais. Está afetada a estabilidade estrutural vertical ou horizontal	
0	Condição de falha: fora de serviço	

Fonte: FHWA (2011)

A metodologia utilizada nos EUA para determinação do estado de condição das pontes, vista na Tabela 13, utiliza-se de abordagem subjetiva, porque o inspetor visita o local e examina cada componente da ponte, em seguida, dá sua nota de avaliação entre 0 (pior condição) e 9 (melhor condição). Além disso, uma classificação de condição descritiva em termos de bom (com pequenos problemas) / razoável (pequena deterioração, ou seja, não afeta a capacidade estrutural) / ruim (deterioração avançada, ou seja, afeta a capacidade estrutural) é fornecida pelo inspetor para cada elemento (impermeabilização, pintura, superfície da estrada etc.), com base nas deficiências encontradas individualmente nos elementos. Esse sistema de classificação tem um valor limitado para determinar as necessidades de reparos e reabilitação (LIAO *et al.*, 2017).

Ainda nos EUA, a *American Association of State Highway and Transportation Officials* (AASHTO) elaborou o *Guide Manual for Bridge Element Inspection* (MBEI) com base no conceito de classificação de condição em nível de elemento. A todos os elementos são atribuídos um dos quatro estados de condição: bom, regular, ruim e grave. O *National Bridge Elements* (NBEs) representam os principais componentes estruturais de pontes (plataformas e lajes, superestrutura, subestrutura, guarda-corpos, mancais e

bueiros) necessários para determinar a condição geral e a segurança do transporte de carga primária membros.

No Reino Unido a avaliação da condição baseia-se principalmente no procedimento prescrito no código de extensão e severidade estabelecido pela *UK's Highways Agency*. Na Tabela 14 tem-se a classificação das pontes no Reino Unido.

Tabela 14 - Classificação de condição da ponte do Reino Unido

Código	Descrição
EXTENSÃO	A Sem defeito significativo
	B Ligeiro, menos de 5% do comprimento/área afetada
	C Moderado; 5% - 20% da área/comprimento afetado
	D Amplo, 20% - 50% afetado
	E Extenso; mais de 50% da área de superfície/comprimento
SEVERIDADE	1 Como novo, ou sem defeito significativo
	2 Sinais iniciais de deterioração, pequeno defeito
	3 Moderado, alguma perda de funcionalidade é esperada
	4 Defeito grave e/ou o elemento está perto da falha
	5 Elemento não funcional/falhou

Fonte: (Liao *et al.*, 2017)

Apesar do modo de classificação do estado da condição observados no Reino Unido, ser de acordo com as informações contidas na Tabela 14, ressalta-se que que as necessidades de manutenção são identificadas com base na adequação estrutural ou segurança, em vez de apenas no estado de condição das estruturas para a *UK's Highways Agency*.

Na Alemanha, as escalas de avaliação das condições variam de 0 (bom) a 4 (muito ruim). Cada componente da ponte é atribuído a três classificações; um para dano estrutural, segurança de tráfego e durabilidade da ponte. Para garantir uma abordagem padrão para a avaliação de danos, 6 níveis de classificações de condição da ponte são definidos, que possui os valores |1,0-1,4| condição estrutural muito boa; |1,5-1,9| condição estrutural boa; |2,0-2,4| condição estrutural satisfatória; |2,5-2,9| condição estrutural insatisfatória; |3,0-3,4| condição estrutural crítica; |3,5-4,0| condição estrutural inadequada. Os possíveis danos são classificados (0 a 4), atribuídos a estabilidade, segurança e durabilidade.

No Japão, as classificações de condição de ponte levam em consideração ações viáveis (de acompanhamento) correspondente à deterioração, isso para serem tomadas as devidas ações de manutenção. O IC é obtido em grupo (IV, III, II, I), estes são avaliados em “risco”, “pequeno risco”, “moderado risco”, “praticamente seguro”. Esse tipo de sistema de classificação de condição é adequado para reparo/reabilitação rápida sem um processo de tomada de decisão. No entanto, as classificações têm problemas em prever a condição futura de uma ponte devido à falta de informações sobre a gravidade explícita e extensão da deterioração (JEONG, 2018).

Na Coreia do Sul, as agências de transporte usam um Índice de Danos, que é a soma normalizada da classificação da condição ponderada dos elementos da ponte. Este é avaliado com base nos dados de condição de elementos coletados por inspetores para fornecer uma avaliação em categorias (A, B, C, D, E). Na China uma ponte pode apresentar estados de condição entre 1-5 e em categoria de (A-E), gerando recomendação correspondente (JEONG, 2018).

O IC usado no Canadá, especialmente pelas províncias de Quebec (Ministério dos Transportes de Quebec - MTQ) e de Ontario é denominado *Bridge Condition Index* (BCI) e possui escala de 1 a 6, de acordo com a severidade dos danos. A severidade do dano leva em conta o tipo de elemento afetado e sua extensão, sendo a condição 1 para condições de danos muito severas e 6 para o estado “como novo”. Na Alemanha um dos BMS utilizados é o programa SIB-Bauwerke. O programa permite selecionar condições pré-determinadas de 0 a 4 para três parâmetros: estabilidade estrutural, segurança e durabilidade (OLIVEIRA, 2019).

No Brasil as principais metodologias para classificação do estado de condição das pontes baseiam-se nas normas DNIT 010/2004-PRO e NBR 9452 (ABNT, 2016). Na primeira durante a inspeção dos elementos da superestrutura, mesoestrutura e infraestrutura das pontes e viadutos deverá ser atribuída uma nota de avaliação, variável de 1 a 5, a qual exprimirá a maior ou a menor gravidade dos problemas existentes no elemento (DNIT, 2016). Na Tabela 15, tem-se a classificação do estado de condição das pontes estabelecido no DNIT 010/2004-PRO.

Tabela 15 - Classificação da condição de OAE

NOTA	CONDIÇÃO DE ESTABILIDADE	DANOS NO ELEMENTO
5	Obra sem problemas	Não há danos nem insuficiência estrutural

4	Obra sem problemas importantes	Há dano, mas não há insuficiência estrutural
3	Obra potencialmente problemática	Há danos com insuficiência estrutural, mas sem comprometer a estabilidade
2	Obra problemática	Há danos com insuficiência estrutural, mas não há risco de colapso
1	Obra crítica	Há danos com insuficiência estrutural, com risco de colapso

Fonte: Adaptada da norma DNIT 010/2004-PRO

A classificação vista na Tabela 15 retrata a gravidade das lesões em cada elemento, indicando as condições de estabilidade e segurança das pontes e dos viadutos (SILVA, 2016). Já a NBR 9452 (ABNT, 2016) apresenta uma diferenciação entre os elementos da estrutura: principal (P), secundário (S) e complementar (C). Contudo, para Silva (2016) o diferencial está nos parâmetros estruturais, funcionais e de durabilidade. Nessa metodologia também são atribuídas notas de 1 a 5. Na Tabela 16 estão descritos os parâmetros estabelecidos na NBR 9452 (ABNT, 2016).

Tabela 16 - Classificação da condição de OAE segundo a NBR 9452 (ABNT, 2016)

NOTA	CONDIÇÃO	ESTRUTURAL	FUNCIONAL	DURABILIDADE
5	Excelente	Condições satisfatórias, defeitos irrelevantes e isolados.	Apresenta segurança e conforto aos usuários.	Perfeitas condições, prevista manutenção de rotina.
4	Boa	Apresenta danos pequenos e em áreas, sem comprometer a segurança estrutural.	Apresenta pequenos danos que não causam desconforto ou insegurança.	Apresenta pequenas e poucas anomalias, que comprometem sua vida útil, em região de baixa agressividade ambiental.
3	Regular	Há danos que podem vir a gerar alguma deficiência estrutural. Mas não há sinais que comprometem a estabilidade da obra.	Apresenta desconforto ao usuário, com defeitos que requerem ações de médio prazo.	Apresenta pequenas e poucas anomalias que comprometem a sua vida útil, em região de moderada à alta agressividade ambiental ou a OAE apresenta moderadas a muitas anomalias, que comprometem sua vida útil, em região de baixa

		agressividade ambiental.		
2	Ruim	Há danos que comprometem a segurança estrutural, sem risco iminente. Sua evolução pode levar ao colapso estrutural.	Funcionalidade visivelmente comprometida com riscos de segurança ao usuário.	Apresenta moderadas a muitas manifestações patológicas, que comprometem sua vida útil, em região de alta agressividade ambiental.
1	Crítica	Há danos que geram grave insuficiência estrutural. Há elementos estruturais em estado crítico, com risco de colapso estrutural.	Não apresenta condições funcionais de utilização.	A OAE encontra-se em elevado grau de deterioração, apontando problema já de risco estrutural e/ou funcional.

Fonte: NBR 9452:2016

Uma síntese das classificações de condição adotadas em alguns países é apresentada na Tabela 17. As informações são adaptadas de várias fontes, tais como artigos científicos (JEONG, 2018; LIAO *et al.*, 2017 e SRIKANTH *et al.*, 2020) e normas (NBR 9452, 2016 e DNIT 010/2004-PRO).

Tabela 17- Classificação da condição de pontes de alguns países

PAÍS	AVALIAÇÃO DA CONDIÇÃO DA PONTE
África do Sul	Avaliações em três categorias: condição física, funcional e econômica (relacionada à extensão dos danos)
Alemanha	Escala de classificação de condição de gravidade 0 (bom) a 4 (muito ruim) e cada componente da ponte recebe três classificações; uma para cada critério (estrutural, segurança de tráfego e durabilidade)
Brasil	Classificação dos componentes da ponte (Laje, vigamento principal, mesoestrutura e pista/acessos), variando entre 1 (Obra crítica) e 5 (Obra sem problemas). Avaliação focada nas condições de estabilidade (DNIT 010/2004-PRO). Classificação dos elementos da ponte (principal, secundário e complementar) variando entre 1 (Crítica) e 5 (Excelente) a partir dos parâmetros estruturais, funcionais e de durabilidade NBR 9452 (ABNT, 2016).
China	Cinco estados de condição: CS I - boa condição, enquanto CS V - condição inaceitável
Coreia do Sul	Classificação de A à E. A- condição perfeita e E- condição de falha

Dinamarca	Classificação de condição de 0 a 5 mais recomendação do inspetor sobre urgência de reparo
EUA	Classificação de condição de 0 e 9 com base na inspeção visual, com (9) sendo excelente condição e a partir de (4) indicando mau estado, até (0) falha, fora de serviço e além da ação corretiva
Finlândia	Classificação de condição de 0 a 4 mais importância no caminho de carga, gravidade, urgência de reparo, condição do elemento de ponte
França	Classificação de condição de 1 a 3 escala. 2E indica necessidade urgente de manutenção especializada, 3U indica necessidade urgente de reparo e S indica uma ameaça à segurança do usuário e uma necessidade urgente de ação
Japão	Classificações: A- nenhum reparo, B- nenhum reparo imediato, reparo necessário, E1- ação de emergência do ponto de vista de segurança e estabilidade estrutural, E2- ação de emergência por causa de outros fatores, reparos mecânicos necessários no curso do trabalho de manutenção regular, S- mais investigações necessárias
Malásia	Escala de classificação de condição de 1 a 5 com (1) nenhum dano encontrado e nenhuma manutenção necessária como resultado da inspeção e (5) está severamente e criticamente danificado e possivelmente afetando a segurança ou o tráfego
Noruega	Escala de classificação de gravidade de 1 a 4 mais um código de consequência (impacto na capacidade de carga, operações de tráfego, custo de manutenção ou ambiente)
UK	Classificação de gravidade de 1 a 5 mais classificação de extensão de A à E

Fonte: Srikanth *et al.* (2020)

As classificações do estado de condição assumem diferentes configurações a depender do país onde estão localizadas as OAEs, suas escalas variam qualitativamente e quantitativamente. No entanto, é comum a utilização dessa variável, entre outras, para a avaliação do desempenho de elementos da infraestrutura urbana. Para modelar o fenômeno da deterioração nas OAEs é preciso utilizar ferramentas matemáticas/estatísticas e suas diferentes abordagens.

2.6 ABORDAGENS PARA AVALIAÇÃO DO ESTADO DE CONDIÇÃO

Os métodos mais utilizados na avaliação de OAEs são processos matemáticos que, baseados em padrões de dados ou resultados, permitem prever eventos ou resultados futuros que são esperados. Para a elaboração de um modelo de avaliação, as seguintes etapas devem ser consideradas (CRONOS QUALITY, 2016): Definição do objetivo do modelo; 2) Realização da coleta de dados; 3) Análise dos dados coletados; 4) Seleção da

(s) técnica (s) de avaliação; 5) Obtenção das avaliações; e, 6) Monitoração do modelo. Sendo assim, o objetivo da modelagem é responder a seguinte questão: "Com base no conhecimento adquirido, o que é mais provável acontecer no futuro?" (ROUSE, 2018).

Nesse sentido, os modelos de avaliação de pontes, são um tipo de ferramenta de verificação de desempenho, e estes são categorizados em empíricos, aqueles baseados em dados e na observação, ou mecanicista, desenvolvidos a partir de modelos analíticos associados a mecanismos de degradação. Apesar das diferentes técnicas, de maneira geral, esses modelos podem apresentar natureza determinística e estocásticas (CAÑAMARES, 2016; OLIVEIRA, 2019). Nesse contexto, aqui serão discutidos com mais detalhes os principais tipos de modelos de avaliação de pontes, apresentando e recorrendo sobre pesquisas atuais nessa temática.

Os modelos determinísticos negligenciam a natureza estocástica dos dados de classificação de condição, propriedades estatísticas não normais e o efeito da censura nas durações de classificação de condição, o que limita a precisão da previsão de tais modelos. Sendo assim, as técnicas de regressão determinística muitas vezes fornecem resultados razoáveis dentro dos limites dos dados disponíveis, mas sua projeção além desses limites pode ser enganosa, limitando sua confiabilidade preditiva (GOYAL *et al.*, 2015).

A modelagem do comportamento das OAEs, por meio de modelos determinísticos também permite estimar o valor médio da variável dependente, tais como a vida remanescente da ponte ou o nível de defeitos existentes. Entretanto, esses modelos necessitam ser atualizados constantemente, por procedimentos manuais, quando uma nova coleta de dados é realizada. Essa atualização pode requerer muito tempo e demandar muitos processos computacionais, o que se caracteriza como uma das desvantagens em se utilizar tais modelos (CHEN *et al.*, 2015).

Morcous *et al.* (2002) destacam que modelos determinísticos permitem calcular as condições previstas, mas não consideram os erros aleatórios que podem ocorrer nessas avaliações. Desse modo, os modelos elaborados para os SGOs podem não ter potencial para capturar os efeitos das séries históricas sobre as condições das pontes, bem como que as incertezas desses modelos não dependem apenas de soluções matemáticas ou estatísticas, sendo indispensável a inserção do conhecimento adquirido e experiência de especialistas (CHEN *et al.*, 2015).

A classificação a priori de pontes comumente usados em modelos determinísticos podem determinar bem a deterioração média de um grupo de pontes, porém de forma imprecisa a deterioração individualmente. Este fenômeno é evidente a partir de um estudo

comparativo de modelos de deterioração desenvolvidos usando duas abordagens diferentes e aplicados a quarenta pontes no banco de dados de pontes da Índia. Verificou-se que as magnitudes dos erros de predição em modelos baseados em técnicas de regressão polinomial eram maiores em comparação com modelos baseados em uma abordagem de cadeia de Markov probabilística (JIANG, 2010).

Os modelos probabilísticos visam capturar a natureza estocástica do processo de deterioração e, assim, melhorar a precisão da avaliação. Nos processos estocásticos os modelos são baseados no estado ou no tempo. Os baseados em estado, a deterioração é modelada por meio de uma probabilidade de transição de um estado de condição para outro em um intervalo de tempo discreto, como as cadeias de Markov. Nos baseados no tempo, a duração que um elemento de ponte permanece em um estado de condição particular é modelado como uma variável aleatória usando distribuições de probabilidade, como as Weibull e Gama, etc., para descrever o processo de deterioração (KOTZE *et al.*, 2015).

Os Modelos probabilísticos fornecem melhores capacidades de extrapolação, contudo, estes assumem que as inspeções em pontes são realizadas em períodos predeterminados e fixos, o que não é verdade, pois a inspeção depende de inúmeros fatores técnicos, financeiros, ambientais, sociais e/ou políticos (GOYAL *et al.*, 2015). Para suprir as deficiências dos modelos determinísticos e estocásticos, a inteligência artificial (IA) pode ser utilizada. As técnicas de inteligência artificial podem compreender sistema inteligentes, redes neurais artificiais, raciocínio baseado em casos, entre outros. Na Tabela 18 são apresentadas algumas vantagens e limitações de modelos de deterioração de pontes segundo (OLIVEIRA, 2019). Ali, percebe-se uma comparação entre modelos determinísticos e estocásticos, além da Inteligência Artificial.

Tabela 18 - Vantagens e limitações das abordagens utilizadas nos modelos de deterioração

Natureza	Modelo	Vantagens	Limitações
Determinística	Modelo de Regressão	*Amplamente utilizado e facilmente compreendido *Considera o histórico de deterioração das pontes	*Apenas a média do IC pode ser previsto *Incertezas inerentes à deterioração de pontes são negligenciadas *Difícil atualização a partir de novos dados
Estocástica	Cadeias de Markov de	*Considera a influência do tempo na deterioração	*Complexa análise, com restrições à comportamentos

	tempo contínuo	*Mensuração da incerteza	com funções de distribuições de probabilidades conhecidas *Complexa atualização dos dados *A natureza da deterioração não é aferida
	Cadeias de Markov de tempo discreto	*Usado para pontes e elementos de pontes *Estados discretos *Mensuração da incerteza *Previsão do IC futuro com base no atual *Eficiente implementação	*Tempos discretos com intervalos regulares *IC subjetivo, baseado na análise dos inspetores *A MPT desconsidera o tempo *A natureza da deterioração não é aferida
Inteligência Artificial	<i>Artificial Neural Network (ANN)</i>	*Modelagem de sistemas com variáveis complexas, com interações multidimensionais e não-lineares	*Atualização devido a novos dados trabalhosa *Resultados sem abordagem Probabilística *Necessita de grande banco de dados

Fonte: Adaptado de Oliveira (2019)

As diferentes abordagens mencionadas anteriormente possibilitaram a adequação dos dados disponíveis ao tipo de modelagem mais adequada a realidade de cada estudo a ser desenvolvido. Isto, notoriamente foi observado em trabalhos citados no decorrer da revisão de literatura realizada, o que possibilitou uma análise crítica dos métodos utilizados na modelagem da deterioração.

2.7 ANÁLISE CRÍTICA DOS PRINCIPAIS MÉTODOS UTILIZADOS NA AVALIAÇÃO DE PONTES

No vasto universo das infraestruturas, onde estão inseridas as pontes, uma análise crítica requereu filtragem de trabalhos, para identificação dos mais relevantes e passíveis de maiores contribuições à pesquisa. Esse processo serviu para uma análise fundamentada do conhecimento atual. Na Tabela 19 estão sintetizadas informações das abordagens principais dos artigos, agrupados em 12 (doze) categorias.

Tabela 19 - Síntese da bibliografia consultada segundo autores e abordagens

ABORDAGENS	AUTORES
Combinações de métodos	Bakó & Gáspár (2018); Calvert <i>et al.</i> (2020) ¹ ; Goyal <i>et al.</i> (2020); Zhang & Marsh (2020); Gao <i>et al.</i> (2018); Alsharqawi <i>et al.</i> (2018); Ghodoosi <i>et al.</i> (2018) ¹ ; Ghodoosi <i>et al.</i> (2018) ² ; Yianni <i>et al.</i> (2016); Saleh <i>et al.</i> (2013); Callow <i>et al.</i> (2013); Orcesi <i>et al.</i> (2010); Durango-cohen & Madanat (2008); Durango-cohen (2007); Marzouka <i>et al.</i> (2018); Neves & Frangopol (2005); Noortwijk & Frangopol (2004); Akgul & Frangopol (2004); Liu & Frangopol (2004); Onoufriou & Frangopol (2002); Hatami <i>et al.</i> (2016); Okasha & Frangopol (2012); Vu & Stewart (2000); Bu <i>et al.</i> (2012); Morcous & Cho (2010); Thompson & Ellis (2004); Lotmis & Madanat (2002); Söderqvist & Veijola (1993).
Modelos Markovianos	Calvert <i>et al.</i> (2020) ² ; Wu <i>et al.</i> (2017); Saydam <i>et al.</i> (2013); Kuhn & Madanat (2005); Morcous & Lounis (2005); Thomas & Sobanjo (2016); Masović & Hajdin (2014); Rens <i>et al.</i> (2003); Rens <i>et al.</i> (1999)
AI/ Machine Learnig	Wei <i>et al.</i> (2020); Kobbacy (2012); Lee <i>et al.</i> (2008); Cheng & Melhem (2005); Lee <i>et al.</i> (2013); Lee <i>et al.</i> (2012); Lee <i>et al.</i> (2011); Morcous <i>et al.</i> (2000)
Revisão de crítica	Srikanth <i>et al.</i> (2020); Costin <i>et al.</i> (2018); Onoufriou & Frangopol (2002); Madanat (1992); Rostam (1989); Stewart <i>et al.</i> (2001); Omar & Nehdi (2016); Thompson (2012); Hachem <i>et al.</i> (1991)
Teorias Bayesianas	Björnsson <i>et al.</i> (2019); Heng <i>et al.</i> (2019); Heitner <i>et al.</i> (2019)
Simulação Monte Carlo	Firouzi e Rahai (2012); Stewart and Rosowsky (1998); Qin e Wang (2007)
Regressão	Goyal <i>et al.</i> (2017); Ruck e Francis (2017); Huang (2006)
Análise de riscos	Thompson <i>et al.</i> (2013)
Análises de dados	Li e Mcneil (2019); Kim e Queiroz (2017)
Poisson	Obama <i>et al.</i> (2013)
Índices de prioridades	Valenzuela <i>et al.</i> (2011)
Índices de condição	Inkoom <i>et al.</i> (2017)

Fonte: Autora (2020)

A Tabela 19 apresenta um apanhado de artigos científicos sobre modelagem da deterioração de pontes, em sua maioria, estudos voltados para a gerência dessas infraestruturas. Percebeu-se que os Sistemas de Gerência de Pontes usam, de maneira geral, modelos de deterioração baseados em cadeia de Markov para análise de nível de rede e priorização de pontes para atividades de manutenção. Há uma tendência ao desenvolvimento de estudos a partir da combinação de métodos de diferentes naturezas, na intenção de suprir as limitações existentes e potencializar as características úteis aos modelos, bem como outras abordagens. Na verdade, os referidos estudos foram realizados na intenção de melhorar os modelos de deterioração para uma visão mais realista.

Nota-se que os modelos determinísticos são rápidos e fáceis de obter com base na análise de regressão. No entanto, pode não estar muito próximo da realidade, pois o

processo de deterioração é aleatório. Os processos estocásticos são de dois tipos principais: baseados no estado e baseados no tempo. Processo baseado em estado é geralmente modelado usando cadeia de Markov e processo baseado em tempo usando distribuições de probabilidade, como *Weibull e Gamma*. Modelos mecânicos são usados para análise de nível do projeto, mas requer muito tempo de computação e dados, que torna quase impossível integrá-lo nos Sistemas de Gerência de Pontes para atividades de manutenção regulares. Os modelos baseados em IA têm grande potencial para superar algumas das limitações dos outros modelos.

A Síntese da bibliografia consultada segundo autores e abordagens, constatou que o processo de modelagem da deterioração, possui em si peculiaridades que devem ser consideradas. Essas são, entre outras: análises em nível de rede ou projeto (a ponte dentro do sistema de transporte e quanto elemento isolado); investigações individuais (avaliação de uma única ponte), por elemento (componentes estruturais e funcionais das pontes) ou em conjunto (parque de pontes); influências externas (VDM, clima, agressividade do meio, entorno, etc.); influências internas (tamanho dos vãos, idade, sistema construtivo, etc.). No Quadro 1, podemos visualizar um resumo do que foi encontrado na literatura em termos de variáveis exploradas para avaliações de pontes.

Quadro 1 - Variáveis explicativas para avaliação do estado de condição.

Variáveis	Tang <i>et al.</i> (2012)	Nieto (2014)	Chang <i>et al.</i> (2017)	Nabizadeh <i>et al.</i> (2018)	Li <i>et al.</i> (2021)	Ozyüksel; Çiftçioglu & Naser (2024)
Idade	X	X	X	X	X	X
Tráfego médio diário	X	X	X	X		X
Ângulo de inclinação			X			X
Comprimento Máx. do vão	X	X	X	X	X	X
Comp. da Estrutura		X	X			
Largura da estrada			X			
Largura do convés			X			
Tráfego médio diário de caminhões			X			
Tipo de estrutura		X		X	X	X

Serviço na ponte			X			
Serviço sob a ponte			X			
Tipo de desgaste superficial	X		X		X	X
Condições meteo.			X			X
Registros de manutenção						
Frequência de Inspeção	X				X	

Fonte: Adaptado de Hasan & Elwakil (2019).

Ainda no Quadro 1 estão registradas as principais variáveis exploradas em estudos de pontes, as mais recorrentes são idade, tráfego médio diário, comprimento máximo do vão, tipo de estrutura, tipo de desgaste superficial. Percebeu-se também uma tendência de inserção de variáveis ambientais, por exemplo, as condições meteorológicas. Desse modo, as variáveis identificadas e selecionadas neste estudo estão alinhadas com as pesquisas atuais para a avaliação do estado de condição de postes.

Foram identificados também na literatura vigente, os principais métodos existentes utilizados na concepção de modelos de avaliação das pontes. Com base na natureza de sua abordagem, sendo ela determinística, estocástica e de inteligências artificiais. Desse modo, a partir do panorama geral dos tipos de modelos de deterioração vistos ficou claro que qualquer que seja a natureza das ferramentas, determinística, estocástica ou de inteligência artificial, todas possuem vantagens e limitações, por isso buscou-se na literatura, pesquisas que utilizaram na concepção dos seus modelos diversas abordagens.

Calvert *et al.* (2020) propõem um modelo preditivo de deterioração de pontes, composto por múltiplas cadeias de Markov de tempo contínuo, estimadas por meio da aplicação de um método de verossimilhança aplicado aos dados disponíveis. O objetivo principal da pesquisa foi desenvolver um modelo com base em múltiplos defeitos e verificar se esse modelo poderia ser calibrado de forma confiável, utilizando dados incompletos de inspeções, onde apenas os dois defeitos mais severos foram registrados. Os autores perceberam que embora o modelo possa ser calibrado utilizando apenas os dados disponíveis, a qualidade do ajuste sofre influência dos dados incompletos, principalmente no que se refere aos estados de condição menos grave.

Goyal (2020) apresentou e comparou dados de inspeção de ponte em todo o estado da Carolina do Norte nos EUA, onde a partir destes usou uma combinação da análise de riscos proporcionais para identificar estatisticamente os fatores mais significativos que afetam a deterioração do componente das pontes ao longo do ciclo de vida em termos de taxas de risco, sendo considerada como uma abordagem inovadora para o desenvolvimento de matrizes de probabilidade de transição usadas na Cadeia de Markov não homogênea em tempo discreto. A limitação foi uso apenas em dados de tempos discretos com intervalos regulares e a natureza da deterioração não ser aferida.

Bu *et al.* (2014) desenvolveram um modelo de previsão retroativo (BPM) capaz de gerar classificações de condição de pontes para anos passados, correlacionando-as com fatores extrínsecos, como clima, tráfego e crescimento populacional. O estudo confirmou que o BPM melhora a precisão da previsão quando utilizado com modelos de deterioração existentes. Comparando os resultados com modelos tradicionais, os autores observaram que o erro de previsão diminui com o uso de mais dados históricos. No entanto, o estudo ressalta a necessidade de desenvolver modelos de deterioração de pontes mais avançados para uso com o BPM.

Canãmares (2016) propôs um modelo com abordagem dupla e amplo espectro, por um lado desenvolve um modelo de deterioração probabilística, baseado em cadeias de Markov e, portanto, outro, é desenvolvido um modelo determinístico baseado em uma relação teórica ajustado a uma função exponencial. Nesse sentido ele desenvolveu um sistema de envelope bilinear simplificado das curvas de deterioração obtidas por ambos os ajustes para cada um dos componentes e populações de histórico, tipologias, processo de construção, etc. de pontes. Um método de otimização é introduzido usando técnicas matemáticas baseadas em algoritmos evolutivos.

Moscoso (2017) realizou um estudo comparativo de modelos de degradação, calibrando-os com dados do NDOT, para identificar o modelo mais adequado para as OAEs sob responsabilidade do DNIT. Concluiu-se que a Regressão de Potência é o método mais apropriado para estimar as curvas de degradação dessas estruturas no Brasil. No entanto, devido à falta de registros históricos de inspeções, utilizou-se a Cadeia de Markov com dados do NDOT para calcular as curvas de degradação das OAEs de concreto do DNIT, reconhecendo que essa abordagem pode não ser ideal devido às diferenças nas características das estruturas e nos contextos nacionais.

Oliveira (2019) determinou taxas de deterioração de pontes usando o modelo estocástico de Cadeias de Markov, enfrentando a falta de registros de inspeções regulares

no Brasil. Com critérios específicos de filtragem e validação dos dados, o estudo alcançou seu objetivo ao analisar dados de vistorias de pontes em rodovias concessionadas de São Paulo. No entanto, o estudo não relacionou as taxas de deterioração às características intrínsecas das pontes ou às variáveis externas, como tráfego e clima, além de se limitar a uma região do país, apesar de ser pioneiro no uso de dados de inspeções brasileiros.

López (2020) desenvolveu um modelo de deterioração usando Cadeias de Markov, propondo uma metodologia para sistematizar a avaliação da condição de pontes federais de concreto no Brasil, com um código computacional em MATLAB que integra técnicas matemáticas. O modelo foi validado com dados fornecidos pela ANTT de São Paulo. No entanto, o código não pode avaliar OAEs de materiais diferentes ao concreto estrutural, e a falta de registros históricos suficientes no Brasil impediu a verificação completa da acurácia e confiabilidade do modelo proposto.

Bjornsson *et al.* (2019) propuseram um modelo de decisão baseado na teoria Bayesiana, cujo objetivo é determinar o tipo de avaliação que deve ser adotado para identificar o estado de condição de uma ponte existente, se ações invasivas (reparos) são necessárias ou se alguma outra opção não invasiva (como modificações no tráfego) possa ser mais adequada. Os autores ainda levam em conta as incertezas associadas à aplicação de diferentes níveis de métodos de avaliação de condições na prática, utilizando uma representação gráfica para essa análise. Como limitação do processo proposto os autores indicam a impossibilidade de realização de ações de avaliação sucessivas e uma possível solução seria a aplicação de um modelo dinâmico de decisão.

Lee *et al.* (2012) abordam a escassez de dados históricos enfrentada pelas agências de gerência e manutenção de pontes e propõem o *Backward Prediction Model* (BPM), um modelo de Inteligência Artificial para gerar classificações históricas de condição de pontes a partir de registros de inspeção limitados. O modelo utiliza dados extrínsecos, como clima, volume de tráfego e crescimento populacional, para superar a falta de dados. Estudos de caso com 9 elementos típicos de pontes em *New South Wales* validaram o BPM, mas os autores destacam a necessidade de identificar mais fatores extrínsecos para melhorar a precisão do modelo.

Mašović & Hajdin (2014) desenvolveram um modelo de deterioração para elementos de pontes na Sérvia, utilizando dados coletados ao longo de 20 anos. Eles aplicaram cadeias de Markov em tempo discreto, mas enfrentaram dificuldades devido à discrepância entre os intervalos de tempo dos registros de condição e os intervalos escolhidos para o modelo. Para resolver isso, utilizaram o algoritmo de *Expectation*

Maximization (EM), obtendo resultados satisfatórios. No entanto, uma limitação importante foi a suposição de que não há correlação entre os processos de deterioração dos elementos da ponte, o que ainda necessita de investigação adicional.

Li & Jia (2020) estudaram modelos estatísticos de classificação da condição no tempo (TICR), onde o tempo que um componente de ponte permanece em uma condição específica é tratado como uma variável aleatória. Utilizando dados de condição do NBI dos EUA, que foram coletados por cerca de 20 anos em alguns estados, eles identificaram que muitos registros são incompletos. Para lidar com isso, os autores propuseram, dentro de uma estrutura bayesiana, uma função de verossimilhança modificada para calibrar modelos de deterioração, incorporando tanto os dados de inspeção completos quanto os incompletos.

A modelagem de dados das avaliações de infraestruturas apresenta muitas possibilidades, como visto por vários trabalhos citados anteriormente, mas também desafios significativos. Como, por exemplo, o lidar com a variabilidade dos dados, que podem ser incompletos, complexos, irregulares, desequilibrados ou apresentar perdas de informação, em conjunto com a subjetividade inerente às inspeções visuais, constitui um cenário desafiador. A qualidade dos registros, muitas vezes influenciada pelo julgamento do inspetor, impacta diretamente a acurácia dos modelos. Diante desse contexto, a comunidade acadêmica tem demonstrado um crescente interesse em desenvolver metodologias robustas para lidar com essas complexidades, visando aprimorar a precisão e a confiabilidade das avaliações de infraestrutura.

2.8 CONTROLE E GARANTIA DA QUALIDADE EM DADOS DE INFRAESTRUTURA

A precisão e a uniformidade das condições registradas da infraestrutura são essenciais para uma gestão eficaz, influenciando decisões relacionadas à manutenção, reabilitação e substituição. Erros nos dados de condição podem distorcer significativamente os resultados dos sistemas de gestão, afetando necessidades orçamentárias e atividades de manutenção. Nesse sentido, destacam-se os termos *Quality assurance and control* (QC/QA) que estão difundidos na literatura e trazem em si reflexões sobre as práticas e procedimentos atuais de controle e a garantia da qualidade

envolvidas no processo amplo do gerenciamento de infraestrutura, mais especificamente das pontes.

Assegurar a confiabilidade dos dados coletados nas inspeções e do julgamento feito pelos inspetores acerca destes, envolve claramente a implementação de mecanismos para auxiliar na avaliação do estado da condição das pontes, bem como ferramentas para monitorar esse processo. Ficou claro que além dos procedimentos regulatórios como manuais e normas bem elaborados, qualificações da equipe de inspeção, treinamento periódico, revisões de relatórios e testes de campo, por isso, percebeu-se extensos esforços de pesquisa realizadas para avaliar e melhorar a qualidade dos dados coletados sobre as condições da infraestrutura.

Buchheit *et al.* (2005) adotaram vários métodos para avaliar e melhorar a qualidade dos dados sobre as condições das infraestruturas civis. Esses métodos incluíram abordagens estatísticas, agrupamento e detecção baseada em padrões, organizados em um esquema de votação. Além disso, desenvolveram métodos específicos para detectar erros nos dados de condições de estradas e pavimentos, utilizando atributos espaciais e temporais (SIABIL; GHARAIBEH, 2017).

Din & Tang (2016) desenvolveram testes lógicos para identificar anomalias temporais e espaciais nos dados do para o *National Bridge Inventory* (NBI). Anomalias temporais foram detectadas comparando dados de diferentes anos para verificar erros lógicos, enquanto anomalias espaciais foram identificadas através do mapeamento geoespacial para localizar conflitos espaciais.

Chen *et al.* (2005) desenvolveram uma ferramenta baseada na internet que identifica anomalias usando um conjunto de regras predefinidas e fornece avaliações sobre as anomalias detectadas. A ferramenta foi aplicada ao conjunto de dados de gerenciamento de pontes do *Pennsylvania Department of Transportation* (PennDOT), que possui itens semelhantes aos dados do NBI, e conseguiu detectar incompatibilidades com requisitos ou códigos. Além disso, foram propostas práticas de gestão para melhorar a qualidade dos dados sobre o estado da infraestrutura.

Migliaccio *et al.* (2014) propuseram um procedimento de coleta de dados de condição que utiliza *Agreement Between Evaluators* (ABE) e *Consistency Over Time* (COV) para reduzir a variação nas classificações individuais e evitar inconsistências nas condições antes e depois das ações de manutenção. Já, Li & Alipour (2021) exploraram textos descritivos de relatórios de inspeção do *Virginia Department of Transportation* (DOT) e propuseram uma estrutura baseada em dados para duas aplicações principais:

recomendação automatizada de condições e controle de qualidade em tempo real. Utilizando uma arquitetura hierárquica com codificadores de redes neurais e um mecanismo de atenção.

Ozyüksel Çiftçioglu & Naser (2024), fizeram um esforço abrangente de coleta de dados para identificar e estimar os efeitos causais em relação à falha de uma ponte sob eventos extremos. Dados observacionais sobre cerca de 299 incidentes foram utilizados para conduzir esta investigação causal e examinar o desempenho das pontes. As descobertas quantificaram os impactos causais de vários fatores que abrangem as características de pontes, demandas de tráfego e tipo de incidente.

Alipour *et al.* (2017) desenvolveram uma nova abordagem para triagem de segurança e avaliação da capacidade de carga de grandes populações de pontes, que busca descobrir padrões até então não vistos no banco de dados do *National Bridge Inventory* (NBI) e estabelecer relacionamentos entre atributos de ponte selecionados e seu status de capacidade de carga. Os modelos resultantes foram validados num conjunto de dados independente e depois comparados com uma série de modelos existentes.

Wang *et al.* (2024) desenvolveram um modelo de fusão que combinam informações, este utiliza redes de extração de recursos específicas para cada tipo de dado e um mecanismo de atenção para ponderar a importância de cada fonte na decisão final. Ao analisar as condições estruturais, foi possível integrar os dados brutos coletados. Essa abordagem, que utiliza a análise Wavelet (ZHANG *et al.*, 2023) e a filtragem de Kalman (MA *et al.*, 2023), possibilita uma avaliação completa e precisa do estado das estruturas. As técnicas de aprendizado de máquinas, estão presentes nas pesquisas citadas anteriormente para avaliar a integridade de pontes, e em outras, vistas no Quadro 2.

Quadro 2 - O quadro sintetiza algumas referências de trabalhos atuais QC/QA

AUTOR(ES)	ABRANGÊNCIA	TIPOS DE COMBINAÇÕES	NATUREZA UTILIZADOS
Liu & El-Gohary (2020)	Nível de Dados	Relatórios de inspeção, medidas de dano	Dados normais
Liu & El-Gohary (2022)	Nível de Dados	Relatórios de inspeção, medidas de dano	Dados normais
Zhang <i>et al.</i> (2023)	Nível de Dados	Decomposição multirresolução de imagens	Dados normais
Ma <i>et al.</i> (2023)	Nível de Dados	Câmera monocromática, acelerômetro	Dados normais
Heng <i>et al.</i> (2019)	Nível de Decisão	Dados de tráfego em tempo real, dados de tráfego antecipado	Dados normais
Zhang <i>et al.</i> (2023)	Nível de Decisão	Potencial de meia célula, radar penetrante no solo, resistência elétrica e ondas ultrassônicas	Dados normais

Miao <i>et al.</i> (2023)	Nível de Decisão	Registros de inspeção, imagens aparentes	Dados normais
Sun <i>et al.</i> (2019)	Nível de Característica e Decisão	Impressões digitais dinâmicas sob vários cenários de dano	Dados normais
Zeng <i>et al.</i> (2020)	Nível de Característica	Medição de rotação, aceleração	Dados experimentais
Dan <i>et al.</i> (2022)	Nível de Característica	Câmera, LiDAR, nuvem de pontos 3D	Dados normais
Wang <i>et al.</i> (2023)	Nível de Característica	Aceleração, deflexão, momento fletor	Dados de simulação

Fonte: Adaptado de Wang *et al.* (2024)

As pesquisas citadas no Quadro 2 exploram diferentes níveis de aplicação, desde a análise de dados brutos de sensores até a tomada de decisões sobre o estado da estrutura. A variedade de dados utilizados, que inclui imagens, medidas de deformação e relatórios de inspeção, demonstra a versatilidade das técnicas de aprendizado de máquina nesse contexto. Os resultados indicam um crescente interesse em automatizar processos de inspeção, tornando-os mais eficientes e precisos (WANG *et al.*, 2024).

3. MÉTODOS DO TRABALHO

Para o desenvolvimento da tese, adotou-se a estratégia de revisão bibliográfica conhecida como “revisão sistemática”. Nesse contexto, foram consideradas e desenvolvidas as seguintes etapas: levantamento bibliográfico, identificação de possíveis abordagens para a pesquisa e o aporte teórico. A elaboração de um mapa conceitual foi fundamental na construção metodológica do estudo. Por definição, o mapa conceitual é uma estrutura que representa um conjunto de conceitos em uma rede de proposições (TAVARES, 2007). Na Figura 11, tem-se o mapa conceitual da pesquisa, dos quais os referidos conceitos foram mencionados no capítulo da revisão de literatura.


Figura 11 - Mapa conceitual da pesquisa



Fonte: Autora (2024)

Na etapa de levantamento bibliográfico foi realizado um mapeamento prévio das normas, manuais técnicos e da produção científica mundial relacionada à gerência de pontes rodoviárias. Neste contexto, foi realizada uma análise macro do cenário atual relacionado à temática, de modo a se obter boas referências para contextualização da problemática e para uma análise posterior mais detalhada. A identificação de possíveis abordagens para a pesquisa e aporte teórico ocorreu a partir da revisão bibliográfica e da elaboração do mapa conceitual. Assim, foi possível a identificação de limitações e lacunas existentes nos estudos já concebidos serviu para, posteriormente, estruturar os objetivos da pesquisa em andamento.

A pesquisa classifica-se como explicativa e quantitativa pois busca estabelecer formas de testar hipóteses e relações causais entre variáveis dependentes e independentes. A metodologia é composta basicamente por 3 etapas: caracterizar; analisar e modelar, vistas na Figura 12.



Fonte: Autora (2024)

3.1 CARACTERIZAÇÃO DO BANCO DE DADOS

3.1.1 Sistema de Gerenciamento de Obra de Artes Especiais (SGO)

O Sistema de Gerenciamento de Obras de Arte Especiais (SGO) do DNIT é atualmente o responsável pelo cadastramento, avaliação e acompanhamento das pontes localizadas em rodovias federais do Brasil. Sendo assim, as pontes abordadas neste estudo fazem parte deste acervo. As avaliações são registradas em relatórios, estas fundamentam-se na norma DNIT 010/2004-PRO, que subsidia a determinação do estado de condição das OAEs, a partir de notas técnicas obtidas por julgamentos feitos por inspetores dessas estruturas em campo. Na Tabela 20, temos as possíveis condições da ponte, em uma escala contínua de 1-5, que reflete da melhor a pior classificação.

Tabela 20 - Classificações do estado de condição da OAE

NOTA	CONDIÇÃO DE ESTABILIDADE	DANOS NO ELEMENTO
5	Obra sem problemas	Não há danos nem insuficiência estrutural
4	Obra sem problemas importantes	Há dano, mas não há insuficiência estrutural
3	Obra potencialmente problemática	Há danos com insuficiência estrutural, mas sem comprometer a estabilidade
2	Obra problemática	Há danos com insuficiência estrutural, mas não há risco de colapso
1	Obra crítica	Há danos com insuficiência estrutural, com risco de colapso

Fonte: Adaptada da norma DNIT 010/2004-PRO

3.1.2 Aquisição e criação de banco de dados próprio

Sobre o processo de aquisição dos dados, destaca-se que este ocorreu de forma lenta. Os relatórios no primeiro momento foram disponibilizados por e-mail, a partir de lotes de 5 arquivos em formato PDF (*Portable Document Format*) por vez. Depois de todos os relatórios recebidos, passava-se para a exploração de suas informações. Um dos tantos desafios encontrados, foi extrair o maior número de informações disponíveis dos relatórios de inspeção e conformar em planilhas de *Excel*, devido ao volume de arquivos. Após o acesso às informações contidas nos relatórios de inspeção de pontes foi possível criar um banco de dados próprio que subsidiou toda a pesquisa.

Para auxiliar na criação do banco de dados próprio da pesquisa, utilizou-se de recursos disponíveis de um *software* gerenciador de planilhas, este armazenou os dados de inventário, do estado de condição e dos danos encontrados nas OAEs de responsabilidade do SGO/DNIT que foram disponibilizadas. Um tempo considerável foi empregado nessa etapa, inviabilizando em termos logísticos para conclusão da pesquisa, utilizar todos os relatórios contidos neste sistema. Vale ressaltar, que o próprio sistema gera uma planilha com informações básicas das pontes, no entanto, essas são insuficientes para nortear as avaliações apresentadas nesse trabalho.

3.1.3 Características das pontes

As OAEs objeto desse estudo são pontes situadas em rodovias-tronco federais e estaduais ou nas rodovias principais de ligação entre esses troncos, classificadas como Classe I. Bem como, aquelas situadas em rodovias de ligação secundárias, mas que haja conveniência em se prever a passagem de veículos pesados, estas classificadas como Classe II. No Quadro 3 estão resumidas as características de pontes do estudo. Os dados

são apresentados em termos de médias e dos desvios-padrão para variáveis envolvidas no estudo.

Quadro 3 - Resumidas das características de pontes do estudo

Característica da ponte	Média (DP)
Comprimento da ponte	38,09 (38,85)
Largura da pista	9,52 (1,97)
Largura da ponte	10,78 (1,75)
Número de vãos	2,55 (1,73)
Número de faixas	2 (0,13)
Ano de inspeção	
2018-2019 (1º ciclo)	192 (53,38%)
2020-2021 (2º ciclo)	167 (46,52%)
Tipo de estrutura	
Viga de Concreto Armado	288 (80,22%)
Outros	71 (19,78%)
Inauguração da Ponte (Idade)	
Até 1960	64 (17,83%)
1960 - 1975	165 (45,96%)
1975 - 1985	42 (11,70%)
Após 1985	88 (24,51%)
Trem Tipo	
24	66 (18,38%)
36	205 (57,10%)
45	88 (24,51%)
Presença de manchas de umidade	
Não	18 (5,01%)
Sim	341 (94,99%)
Presença de infiltrações no concreto	
Não	17 (4,73%)
Sim	342 (95,26%)
Presença de lixiviação e mancha de carbonatação	
Não	54 (15,04%)
Sim	305 (84,96%)
Presença de concreto desagregado	
Não	80 (22,28%)
Sim	279 (77,71%)
Presença de junta danificada ou inexistente ou expelida	
Não	3 (0,83%)
Sim	356 (99,17%)
Presença de deslocamento de concreto com armadura exposta	
Não	237 (66,02%)
Sim	122 (33,98%)
Presença de ferragem principal muito oxidada em pontos localizados	
Não	318 (88,56%)
Sim	41 (11,42%)
Insuficiência estrutural	
Insuficiente	99 (27,58%)
Suficiente	260 (72,42%)

Fonte: Elaborado pela autora

Vale ressaltar, que as pontes abordadas neste estudo estão localizadas no estado da Paraíba, 192 inspecionadas no período de jun/2018 à nov/19 (primeiro ciclo) e 167 em maio/2020 à ago/2021 (segundo ciclo). Quanto ao sistema construtivo, a viga de concreto armado foi o mais utilizado na construção de pontes. Em relação ao Trem-tipo e idade das pontes verificou-se lacunas no preenchimento dessas informações. No entanto, o manual do DNIT (2004) apresenta a evolução das seções tipo de OAEs ao longo do tempo, estas diretamente relacionadas a largura da ponte, isso por que a evolução das seções tipo das OAEs ocorre a partir do aumento gradativo da largura total e da largura útil ao longo do tempo.

A identificação das variáveis do referido estudo partiu, antes de tudo, de uma revisão da literatura, na qual algumas pesquisas revelaram as principais variáveis utilizadas na investigação do estado de condição das pontes, conforme destacado no capítulo anterior. Desse modo, foi possível conformar um panorama geral do que foi encontrado na comunidade científica em relação ao que está disponível no banco de dados do SGO/DNIT.


Dessa forma, a partir dos relatórios de inspeções, foi possível catalogar as características das pontes, sistematizando-as em fatores de identificação e inspeção. Essas características foram agrupadas em 16 variáveis, resumidas da seguinte maneira:

- Fatores de identificação: comprimento da ponte, largura da pista, largura da ponte, número de vãos, número de faixas, tipo de estrutura, inauguração da ponte (idade) e trem-tipo.

- Fatores de inspeção: ano de inspeção, manchas de umidade, infiltrações no concreto, lixiviação e mancha de carbonatação, concreto desagregado, junta danificada ou inexistente ou expelida, deslocamento de concreto com armadura exposta e ferrugem principal muito oxidada em pontos localizados.

No tocante ao estado de condição da OAE, que tem por objetivo retratar as anomalias presentes nos elementos da ponte, indicando as condições de estabilidade e funcionalidade, tem-se na Figura 13 a representação de parte da malha rodoviária da Paraíba, onde estão localizadas as pontes da referida pesquisa.

Figura 13 - Mapa de pontes rodoviárias localizadas no Estado da Paraíba.




Fonte: Autora (2020)

Na Figura 17 ficou claro que a maioria das OAEs desse estudo está localizada na área interiorana do Estado da Paraíba, assim como a minoria está localizada no litoral, mas apresentando-se em melhores condições, talvez isso se deva ao fato destas últimas serem mais solicitadas em termos de volume de tráfego e atenção do poder público. Percebe-se também que é na BR – 230 que estão localizadas a maioria das pontes do estudo.

Na Figura 14 observa-se uma síntese do estado de condição das pontes pesquisadas a partir da norma DNIT 010/2004-PRO para o 1º ciclo de inspeções, finalizado em 2019.

Figura 14 - Notas do estado de condição das pontes



Fonte: Autora (2020)

De acordo com a Figura 18 as estruturas em situação de "obra potencialmente problemática", aquelas com nota 3 à "obra crítica", aquelas com nota 1, representam 76,6% do total das pontes analisadas neste artigo. As estruturas em situação de “obra sem problema importante”, aquelas com nota 4, em torno de 23,4%. Não foram observadas pontes em situação de “Obra sem problemas”, aquelas de nota 5.

3.2 REGRESSÃO LOGÍSTICA E O PROCEDIMENTO DE SELEÇÃO DE VARIÁVEIS

3.2.1 Regressão logística binomial para avaliar o julgamento de insuficiência estrutural

Para explicar a relação da insuficiência estrutural e os pareceres dos avaliadores, as categorias de resposta foram ordenadas, no modelo de regressão logística binomial, onde o evento que está sendo modelado não apenas tem um resultado em uma categoria específica, mas também preserva informações sobre as categorias de resposta que são ordenadas. A expressão utilizada procura explicar a probabilidade de haver uma avaliação de que ocorre insuficiência estrutural (IE):

$$p = P(IE = "Sim")$$

Na regressão logística nesse contexto, o cálculo da probabilidade p é dada pela Equação 5.

$$p = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \beta_2 X_2 \dots + \beta_k X_k)}} \quad (5)$$

Em que:

p = probabilidade da variável dependente ser 1 (por exemplo, a probabilidade de sucesso ou do evento ocorrer).

β_0 = O termo de intercepto (uma constante).

$\beta_1 + \beta_2 \dots + \beta_k$ = os coeficientes associados a cada preditor $X_1 + X_2 \dots + X_k$. Esses coeficientes representam a influência do preditor correspondente sobre o logaritmo das chances do resultado.

$X_1 + X_2 \dots + X_k$ = as variáveis independentes (preditoras) no modelo.

No entanto, a equação também pode ser reescrita de modo que seja explicitada a chance (que é a razão entre a probabilidade de ocorrer insuficiência estrutural e a probabilidade de não ocorrer):

$$CHANCE (IE = "Sim") = \left(\frac{p}{1-p} \right)$$

Portanto, a Equação 5 pode ser escrita no formato da Equação 6 para explicitar a chance de haver insuficiência estrutural.

$$CHANCE (IE = "Sim") = e^{\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k} \quad (6)$$

$$CHANCE (IE = "Sim") = e^{\beta_0} \cdot (e^{\beta_1})^{X_1} \cdot (e^{\beta_2})^{X_2} \dots (e^{\beta_k})^{X_k} \quad (7)$$

Os valores de e^{β_i} são chamados razão da chance (*Odds Ratio*) e indicam o quanto tende a aumentar a chance de avaliar uma OAE como tendo insuficiência estrutural quando as variáveis X_i aumentam. A Equação 6 explicita a razão da chance mostrada na Equação 7.

$$CHANCE (IE = "Sim") = k \cdot (OR_1)^{X_1} \cdot (OR_2)^{X_2} \quad (8)$$

, sendo:

$$OR_1 = e^{\beta_1}, OR_2 = e^{\beta_2} \text{ e } k = e^{\beta_0}$$

A regressão logística foi utilizada inicialmente para investigar as variáveis significativas e modelar a relação entre variável dependente e variáveis explicativas. Em seguida, o procedimento de seleção das variáveis (*Stepwise Backward*) usado definiu as que permaneceriam para modelagem a partir do valor de Akaike (AIC), o conjunto de variáveis que maximizava a parcimônia do modelo, ou seja, que explicava a maior variância com o menor número de parâmetros.

Para discutir a relação entre variáveis usando regressão logística é comum usar a razão da chance (*Odds Ratio*), calculada a partir dos parâmetros associados às variáveis. Essa medida indica o quanto tende a aumentar a chance de ocorrer um evento descrito por uma variável dependente quando há o aumento de uma unidade em uma variável independente. No processo de seleção das variáveis, temos as estimativas e o intervalo de confiança para razão da chance do modelo, bem como sua significância com base no teste de *Wald*. As estimativas intervalares foram para um nível de confiança de 95%. Essas estimativas indicam um intervalo de possibilidades da razão da chance considerando-se uma margem de erro.

O teste da razão de verossimilhança foi utilizado para verificar se o ajuste é suficiente para inferir sobre o evento descrito pela variável dependente (que é a ocorrência de insuficiência estrutural). A curva ROC foi empregada para determinar o melhor ponto de corte para a classificação. Essa curva é obtida estimando a taxa de acertos (taxas de

verdadeiros positivos e de verdadeiros negativos) e erros (taxas de falsos positivos e falsos negativos) nas classificações. Essa medida é a área abaixo da curva (AUC), variando entre 0,5 e 1, diz-se que o modelo é mais assertivo quando a AUC tem valores próximos de 1 e que erra mais quando tem valores próximos de 0,5.

3.2.2 Regressão Logística Ordinal para avaliar as notas atribuídas ao estado de condição

Para explicar as notas atribuídas ao estado de condição das pontes, onde os valores da variável dependente possuem uma ordem ou classificação; variando de 1 a 5, sendo (1) obra crítica e (5) obra sem problema, pode-se dizer que as classificações da ponte são dados discretos ordinais, utilizou-se os recursos da regressão logística ordinal, com a variável dependente expressa por quatro classes, a equação pode ser expressa como segue, considerando a classe 1 como nível de referência:

$$chance(Y \geq 2) = \frac{P(Y \geq 2)}{P(Y \leq 2)} = e^{\beta_{01} + \beta_1 X_1 + \dots + \beta_k X_k} = e^{\beta_{02}} \cdot (e^{\beta_1})^{X_1} \dots (e^{\beta_k})^{X_k} \quad (9)$$

$$chance(Y \geq 3) = \frac{P(Y \geq 3)}{P(Y \leq 3)} = e^{\beta_{02} + \beta_1 X_1 + \dots + \beta_k X_k} = e^{\beta_{03}} \cdot (e^{\beta_1})^{X_1} \dots (e^{\beta_k})^{X_k} \quad (10)$$

$$chance(Y \geq 4) = \frac{P(Y \geq 4)}{P(Y \leq 4)} = e^{\beta_{03} + \beta_1 X_1 + \dots + \beta_k X_k} = e^{\beta_{04}} \cdot (e^{\beta_1})^{X_1} \dots (e^{\beta_k})^{X_k} \quad (11)$$

As Equações 9, 10 e 11 expressam conjuntamente o modelo de regressão logística ordinal. Sob a forma que estão apresentadas explicitam a chance da variável dependente Y ser expressa por uma classe mais alta. Porém, as equações podem ser reescritas de forma que explicitem a probabilidade da variável dependente Y ser expressa por uma classe mais alta como mostrados nas Equações 12, 13 e 14.

$$P(Y \geq 2) = \frac{1}{1 + e^{-(\beta_{02} + \beta_1 X_1 + \dots + \beta_k X_k)}} \quad (12)$$

$$P(Y \geq 3) = \frac{1}{1 + e^{-(\beta_{03} + \beta_1 X_1 + \dots + \beta_k X_k)}} \quad (13)$$

$$P(Y \geq 4) = \frac{1}{1 + e^{-(\beta_{04} + \beta_1 X_1 + \dots + \beta_k X_k)}} \quad (14)$$

Essas probabilidades (12, 13 e 14) podem ser combinadas para obter a probabilidade de ocorrer cada uma das classes, como mostrado nas Equações 15, 16, 17 e 18.

$$P(NT = 4) = P(Y \geq 4) \quad (15)$$

$$P(Y = 3) = P(Y \geq 3) - P(Y \geq 4) \quad (16)$$

$$P(Y = 2) = P(Y \geq 2) - P(Y \geq 3) \quad (17)$$

$$P(Y = 1) = 1 - P(Y \geq 2) \quad (18)$$

Substituindo as Equações 12, 13 e 14 nas Equações 15, 16, 17 e 18, são obtidas as equações das probabilidades de cada classe da variável dependente Y ocorrer, dados os valores das variáveis.

$$P(Y = 4) = \frac{1}{1 + e^{-(\beta_{04} + \beta_1 X_1 + \dots + \beta_k X_k)}}$$

$$P(Y = 3) = \frac{1}{1 + e^{-(\beta_{03} + \beta_1 X_1 + \dots + \beta_k X_k)}} - \frac{1}{1 + e^{-(\beta_{04} + \beta_1 X_1 + \dots + \beta_k X_k)}}$$

$$P(Y = 2) = \frac{1}{1 + e^{-(\beta_{02} + \beta_1 X_1 + \dots + \beta_k X_k)}} - \frac{1}{1 + e^{-(\beta_{03} + \beta_1 X_1 + \dots + \beta_k X_k)}}$$

$$P(Y = 1) = 1 - \frac{1}{1 + e^{-(\beta_{02} + \beta_1 X_1 + \dots + \beta_k X_k)}}$$

3.3 REDES BAYESIANAS

Outra alternativa utilizada para investigar as relações entre as variáveis independentes a partir da regressão logística binomial, foram as redes Bayesianas Discretas, estas são ferramentas probabilísticas que representam variáveis e suas dependências em um grafo, permitindo prever resultados e atualizar probabilidades com base em novas informações. Diferente da regressão logística, as redes bayesianas permitem considerar as inter-relações entre variáveis independentes para inferir sobre a insuficiência estrutural, a variável dependente (RIZQIANSYAH; CAPRANI, 2024).

3.4 ALGORITMOS DE MACHINE LEARNING

Análises adicionais utilizando técnicas de aprendizagem de máquinas ML (Machine Learning) foram exploradas na intenção de refinar os resultados obtidos. Juntamente com a aplicação das abordagens mencionadas; as variáveis explicativas foram exploradas e examinadas para verificar a relação do julgamento de insuficiência estrutural com as características observadas das pontes e o impacto na classificação do estado da condição. Desse modo, após identificar as variáveis, segue efetuando uma análise preliminar da capacidade preditiva de seis algoritmos do campo da aprendizagem de

máquinas sobre aquela relação, investigando também o ganho de informação que pode ser obtido com o uso de cada um desses. Os algoritmos explorados para a modelagem proposta foram, regressão logística, naive bayes, random forest, k-nearest neighbours, support vector machine e redes neurais perceptron multicamadas (LANTZ, 2013; LEISTMEISTER, 2015 e NWANGANGA e CHAPPLE, 2020).

Vale ressaltar, que avaliações baseadas em *Machine Learning* (ML) envolve o estabelecimento de uma representação estatística da estrutura por meio de dados de inspeção e a avaliação se a condição é normal ou não em mudanças na função de densidade de probabilidade. Por esse motivo, esses métodos também são conhecidos como métodos de reconhecimento de padrões (BAO *et al.*, 2019).

3.4.1 Regressão Logística

A regressão logística é um algoritmo estatístico amplamente utilizado para resolver problemas de classificação, especialmente em casos binários, onde a variável dependente possui apenas dois resultados possíveis, como "sim/não" ou "sucesso/falha". No entanto, também pode ser estendida para classificações multiclases (LU; WANG; TOLLIVER, 2019).

3.4.2 Naive Bayes

O algoritmo *Naive Bayes* é um dos classificadores probabilísticos mais simples e eficazes, baseado no Teorema de *Bayes* com a suposição de independência condicional entre os atributos. Ele é amplamente utilizado para problemas de classificação (SUN *et al.*, 2018).

3.4.3 Random Forest

O *Random Forest* é um algoritmo de aprendizado de máquina baseado em conjuntos, utilizado tanto para classificação quanto para regressão. Ele combina múltiplas árvores de decisão para formar um modelo robusto, melhorando a precisão e evitando o problema de *overfitting* comum nas árvores individuais (WU *et al.*, 2024).

3.4.4 *K-nearest Neighbours*

O algoritmo K-Nearest Neighbors (K-NN) é um dos métodos mais simples e intuitivos de aprendizado supervisionado, utilizado tanto para classificação quanto para regressão. O princípio básico do K-NN é que, para realizar uma previsão sobre uma nova amostra, o algoritmo leva em consideração os K vizinhos mais próximos dessa amostra, baseando a predição no comportamento desses vizinhos (KAZANTZI *et al.*, 2024).

3.4.5 *Support Vector Machine*

O *Support Vector Machine (SVM)* é um algoritmo de aprendizado supervisionado utilizado tanto para classificação quanto para regressão. Ele é particularmente eficaz em problemas de classificação binária e se destaca por sua capacidade de encontrar um hiperplano ótimo que separa as classes com a maior margem possível (JOOTOO; LATTANZI, 2017; NIKNAM *et al.*, 2024).

3.4.6 *Redes Neurais Perceptron Multicamadas*

O *Multi-Layer Perceptron (MLP)* é um tipo de rede neural artificial usada principalmente em tarefas de classificação e regressão. O MLP é uma forma de aprendizado profundo (*Deep Learning*), composta por várias camadas de neurônios artificiais que trabalham de maneira hierárquica para aprender padrões complexos a partir de dados. Ele é uma extensão do *perceptron* simples, que só pode resolver problemas linearmente separáveis, para lidar com problemas mais complexos e não linearmente separáveis (ELSHAZLI *et al.*, 2024).

Estes foram treinados considerando 75% da amostra e a validação foi testada para 25% restante do grupo do estudo. As acurácias foram comparadas a partir do método de validação cruzada. Nesse método o conjunto de pontes sob estudo foi dividido em dez partes, nove dessas foram utilizadas para se fazer o treinamento dos algoritmos e uma dessas foi usada para fazer o teste de validação (obtendo as medidas de acurácia). Esse procedimento é repetido dez vezes alternando as partes usadas como grupo de treinamento e grupo de teste e para finalizar utiliza-se a média das acurácias obtidas nas classificações. A validação cruzada foi repetida 30 vezes para verificar a estabilidade das medidas de comparação dos algoritmos e da ordem de desempenho. Para avaliar a qualidade da predição dos métodos usados utilizou-se as medidas de acurácia, coeficiente

Kappa, taxa de não informação e o teste de ganho de informação. O coeficiente de *Kappa* é uma medida de acurácia aplicando uma correção para a taxa de não informação. A interpretação do valor do coeficiente *Kappa* geralmente segue esta escala:

- $Kappa < 0$: Concordância abaixo do esperado pelo acaso.
- $Kappa = 0$: Concordância igual ao esperado pelo acaso.
- $0 < Kappa < 0.2$: Concordância fraca.
- $0.2 \leq Kappa < 0.4$: Concordância razoável.
- $0.4 \leq Kappa < 0.6$: Concordância moderada.
- $0.6 \leq Kappa < 0.8$: Concordância substancial.
- $0.8 \leq Kappa \leq 1$: Concordância quase perfeita.

Posteriormente, a comparação é realizada por meio de procedimentos mais robustos no campo da aprendizagem de máquina, considerando a aplicação de repetidas vezes do método de avaliação *Cross-Validation* e aplicando testes de hipótese (teste de *Friedman* e o teste de *Nemenyi*) para verificar se o ganho na assertividade pode ser considerado significativo. O teste de *Friedman* foi utilizado para comparar o desempenho entre os algoritmos, na intenção de verificar se há diferenças significativas em pelo menos 2 dos algoritmos. Já o teste de *Neminyi*, foi realizado para verificar entre quais algoritmos há diferenças.

3.5 SOFTWARE UTILIZADO PARA ANÁLISE E MODELAGENS

O software R-Project versão 4.3.3 (R CORE TEAM, 2024) foi utilizado para implementar todo o procedimento computacional e obter as informações necessárias sobre: o processo de seleção das variáveis; estimação dos parâmetros dos modelos de regressão logística; treinamento dos algoritmos de machine learning e das redes bayesianas; cálculo das métricas de avaliação das predições; aplicação dos testes de hipótese necessários.

O modelo de regressão logística binomial foi ajustado utilizando a função *glm* da biblioteca básica *boot*. A regressão logística ordinal foi ajustada utilizando a função *lrm* da biblioteca *rms*. Para o treinamento dos algoritmos de machine learning foram usadas funções das bibliotecas *e1071*, *class*, *randomForest* e *h2o*. As métricas de avaliação foram obtidas usando funções das bibliotecas *ROCR*, *caret* e *caTools*. Outras funções e bibliotecas complementares foram utilizadas (LANTZ, 2013; LEISTMEISTER, 2015 e NWANGANGA e CHAPPLE, 2020). (Ver no Anexo I).

4. RESULTADOS E DISCUSSÕES

Este capítulo apresenta os resultados alcançados a partir da metodologia utilizada na pesquisa, ele foi dividido em 3 seções; a primeira com foco na investigação da relação entre o julgamento da insuficiência estrutural e características das pontes. Nesta parte foi utilizada a regressão logística binomial, bem como a exploração de algoritmos de *Machine Learning*. Para uma investigação adicional das relações entre as variáveis independentes foi utilizada as Redes Bayesianas discretas.

A segunda, com ênfase na possível explicação da nota atribuída para o estado de condição das pontes. Para essa abordagem foi utilizado os atributos da Regressão Logística Ordinal. Vale ressaltar, que todas os recursos utilizados foram na intenção de subsidiar uma modelagem explicativa/analítica de informações oriundas de relatórios de inspeções disponíveis no banco de dados do SGO/DNIT.

E a terceira, última parte, na geração de cenários para o julgamento de insuficiência estrutural bem como a atribuição de notas em diferentes contextos a partir das características observadas das pontes em campo e registradas em relatórios de inspeção.

4.1. INVESTIGAÇÃO DA RELAÇÃO ENTRE JULGAMENTO DA INSUFICIÊNCIA ESTRUTURAL E CARACTERÍSTICAS DAS PONTES

Inicialmente foram consideradas no estudo 14 variáveis. Porém, em uma análise inicial de correlação utilizando o método de Spearman para as variáveis quantitativas (Comprimento da pista, trem tipo, largura da ponte, número de vãos, largura da pista) verificou-se que havia uma correlação forte entre a largura da pista e a largura da ponte ($r = 0,96$), e entre a largura da pista e o trem tipo ($r = 0,75$). Portanto, das três variáveis, apenas a largura da pista foi considerada no modelo inicial do método *stepwise backward*. De modo que o procedimento de seleção das variáveis levou em consideração inicialmente 12 variáveis. A Tabela 21 mostra o procedimento de seleção.

Tabela 21 - Processo de seleção *Stepwise*

Etapa	AIC	Número de características	Característica excluída do modelo
Inicial	335,67	12	-
1	333,67	11	Presença de junta danificada ou inexistente ou expelida
2	331,67	10	Presença de infiltração no concreto
3	329,8	9	Presença de manchas de umidade
4	327,95	8	Comprimento da edificação
5	326,27	7	Largura da ponte
6	324,85	6	Presença de lixiviação e mancha de carbonatação
7	324,77	5	Número de vãos

Fonte: Autora (2023)

No procedimento de *Stepwise Backward*, considerou-se inicialmente 12 variáveis, sendo retirada uma a cada etapa. As retiradas ocorreram até que o valor do AIC aumenta indicando que em termos de parcimônia o modelo se apresenta pior quando a variável é retirada. Nessa seleção, modelos com menos variáveis e maior capacidade explicativa são considerados melhores.

4.1.1 Abordagem do julgamento da insuficiência estrutural a partir da regressão logística binomial

O modelo de regressão logística resultante contém cinco variáveis, mas nem todas as variáveis selecionadas apresentam parâmetros significativos associados. Para discutir a relação entre variáveis usando regressão logística é comum usar a razão da chance (odds ratio). Essas estimativas indicam um intervalo de possibilidades da razão da chance considerando-se uma margem de erro. A Tabela 22 apresenta as estimativas intervalares para um nível de confiança de 95%.

Tabela 22 - Modelo selecionado pelo *Stepwise*

Característica	Odds Ratio	IC95%	z	p
Presença de deslocamento de concreto com armadura exposta				
Não	-	-	-	-
Sim	4,41	(2,1148; 10,0012)	3,77	0,0002
Presença de concreto desagregado com armadura exposta e oxidada				
Não	-	-	-	-
Sim	5,34	(2,8689;10,1298)	5,22	1,76.10 ⁻⁷
Idade da edificação				

Após 1985	-	-	-	-
1975 -1985	1,06	(0,3939; 2,6360)	0,11	0,9088
1960 - 1975	0,07	(0,0015;0,3029)	-3,43	0,0006
Até 1960	0,11	(0,0013; 0,6605)	-2,22	0,02611
Largura da pista (em metros)	1,34	(0,9335; 2,0300)	1,48	0,1397
Tipo de estrutura				
Viga de Concreto Armado	-	-	-	-
Outros	0,44	(0,2115; 0,9079)	-2,22	0,0263

Fonte: Autora (2023)

Ainda na Tabela 22, infere-se que há um aumento da chance de haver insuficiência estrutural de mais de 10 vezes (note que o limite superior do intervalo é de 10,0012) para pontes onde se observa a presença de deslocamento de concreto com armadura exposta. A chance de se ter uma insuficiência estrutural tende a aumentar em mais de 4 vezes quando se observa a presença de deslocamento de concreto com armadura exposta; tende a aumentar em mais de 5 vezes quando se identifica presença de concreto desagregado com armadura exposta oxidada; é 6% maior quando a ponte foi inaugurada entre 1975 e 1985 em comparação com aquelas inauguradas após 1985; tende a ser 34% maior para cada 1 metro acrescentado na largura da pista; e é esperado que seja 66% menor em outros tipos de pontes comparadas com aquelas com vigas de concreto armado.

Porém, nem todas essas tendências se mostraram significativas. A diferença na chance não é significativa entre as pontes inauguradas após 1985 e aquelas que foram entre 1975 e 1985. Também não se mostrou significativa a tendência de chances menores para pistas mais largas. Para ter melhores estimativas do efeito das variáveis foram mantidas apenas aquelas com parâmetros significativos. Por essa razão agrupou-se duas das classes da idade da ponte (o período “após 1985” e “de 1975 a 1985”). Na Tabela 23, temos o modelo I com as variáveis significativas e sem a largura da pista.

Tabela 23 - Modelo I contendo apenas variáveis significativas e sem a largura da pista

Característica	Odds Ratio	IC95%	z	p
Presença de deslocamento de concreto com armadura exposta				
Não	-	-	-	-
Sim	4,10	(2,0027;9,1181)	3,67	0,000234
Presença de concreto desagregado com armadura exposta e oxidada				
Não	-	-	-	-

Sim	5,12	(2,7806; 9,5758)	5,19	2,06.10 ⁻⁷
Idade da edificação				
Após 1975	-	-	-	-
1960 - 1975	0,14	(0,0608;0,3251)	-4,57	4,84.10 ⁻⁶
Até 1960	0,34	(0,1770;0,6580)	-3,21	0,001347
Tipo de estrutura				
Viga de Concreto Armado	-	-	-	-
Outros	0,46	(0,2300; 0,9359)	-2,15	0,03131

Fonte: Autora (2023)

A partir da Tabela 23, percebeu-se que mesmo desconsiderando as variáveis com parâmetros não significativos, as estimativas da razão da chance e dos intervalos de confiança se apresentaram aproximados daqueles presentes na Tabela 22. Também foi possível obter o modelo II, este visto na Tabela 24, contendo apenas parâmetros significativos, sem considerar a idade da ponte. Quando excluída do modelo essa variável, a estimativa do parâmetro associado a largura da pista passou a ser significativo.

Tabela 24 - Modelo II contendo apenas parâmetros significativos e sem a idade da ponte

Característica	Odds Ratio	IC95%	z	p
Presença de deslocamento de concreto com armadura exposta				
Não	-	-	-	-
Sim	4,378	(2,2637; 9,1858)	-2,753	0,005897
Largura da pista (em metros)	0,7744	(0,6772; 0,8826)	-3,792	0,000149
Tipo de estrutura				
Viga de Concreto Armado	-	-	-	-
Outros	0,4336	(0,2387; 0,7871)	4,169	3,06.10 ⁻⁵

Fonte: Autora (2023)

No entanto, ainda na Tabela 24 se observa uma expressiva alteração em relação a largura da pista (enquanto na Tabela 22 há um indicativo que a chance de ocorrer insuficiência estrutural é maior para pontes com pistas mais largas, na Tabela 24 observa-se que a chance tende a diminuir para pontes com maiores larguras de pista). Percebe-se ainda na Tabela 24, que para cada 1 metro adicional na largura da pista da ponte espera-

se que a chance de se ter uma insuficiência estrutural reduza em 22,35% (visto que temos $0,7744 = 1 - 0,2236$). Pela estimativa intervalar com nível de confiança de 95% é possível, que ao considerar uma margem de erro, essa redução da chance possa ser de até 11,74% (já que temos $0,8826 = 1 - 0,1174$).

A Tabela 25 apresenta algumas informações adicionais sobre os dois modelos que contém apenas parâmetros significativos resultantes da análise preliminar por meio da regressão logística. Os dois modelos resultantes da análise apresentam um resultado favorável, visto que o teste da razão de verossimilhança rejeita a hipótese de que todos os parâmetros do modelo são iguais a zero (situação onde as variáveis não teriam nenhum efeito sobre a insuficiência estrutural).

Tabela 25 - Comparação dos modelos com parâmetros significativos

Indicador da qualidade do modelo	Modelo	
	I	II
Melhor ponto de corte	0,5514	0,5286
Acurácia com o melhor ponto de corte	0,8273	0,7019
Área abaixo da curva	0,8314	0,7346
Valor p do teste da razão de verossimilhança	0,03207	3,98.10 ⁻⁷

Fonte: Autora (2023)

Ainda na Tabela 25 há um indicativo do valor do ponto de corte, neste em nenhum dos dois modelos apresentam valor de AUC próximos de 0,5, porém o modelo I apresenta um valor superior da medida, sendo considerado melhor ajustado. Outra medida de qualidade do ajuste dos modelos, que é a acurácia para o melhor ponto de corte considerado (esse melhor ponto de corte é aquele onde se tem uma maior diferença entre as taxas de verdadeiros positivos e falsos positivos). Essa medida indica o percentual de classificações efetuadas na amostra (usada para estimar os parâmetros do modelo) que foram corretas. Para o modelo I temos que 82,73% das classificações realizadas foram acertadas, enquanto para o modelo II esse percentual de acertos é de 70,19%. Portanto o modelo I também pode ser considerado melhor para efetuar as classificações, de modo que seria mais assertivo utilizar a idade da ponte do que a largura da pista para inferir sobre a insuficiência estrutural.

A regressão logística ordinal é uma extensão da regressão multinomial que acredita-se ser teoricamente apropriada e viável para modelar alterações da classificação do estado de condição geral das pontes, bem como avaliações mais específicas. Os

modelos logísticos têm sido amplamente adotados na modelagem de dados em acidentes com veículos motorizados e, em menor grau, na deterioração de tubulações e de serviços públicos de águas residuais e na deterioração de pontes (HUANG, 2006; GOYAL *et al.*, 2017; RUCK; FRANCIS, 2017; BALOMENOS *et al.*, 2020).

No estudo de Balomenos *et al.* (2020), foram desenvolvidos modelos de fragilidade para vãos individuais de diferentes classes de pontes considerando a variabilidade espacial das cargas de ondas e variações nas características estruturais. São empregadas análises dinâmicas não lineares para calcular a resposta estrutural e a regressão logística em etapas é utilizada para derivar os modelos preditivos de fragilidade.

O trabalho de Wijesuriya & Tennant (2022) usou a regressão logística binária para verificar a probabilidade de uma ponte estar em risco, onde a modelagem foi expressa em termos, da idade, carga, sistema construtivo e condições gerais. O que difere da abordagem utilizada nesta tese, e que veio como um diferencial, foi uma análise específica em termos do julgamento de insuficiência estrutural, a partir de fatores, como: idade, tipo de estrutura e dois outros relacionados aos danos encontrados nas pontes.

Vale ressaltar, que o procedimento de seleção de variáveis significativas também foi observado em outros estudos, tais como, Hasan & Elwakil (2019) que desenvolveram modelos com a regressão estocástica para analisar o comportamento da superestrutura de pontes de concreto pré-moldado na Califórnia. E Chang, Maguire & Sun (2017) que propuseram uma ferramenta para mitigar o viés humano na seleção de variáveis explicativas para a modelagem da deterioração de pontes.

Desde a identificação, seleção e definição das variáveis significativas que permaneceriam na modelagem, houve a preocupação de que o modelo fosse capaz de representar uma realidade específica de forma simplificada a partir de um número menor de variáveis, facilitando possivelmente sua implementação e processamento mais tarde. Sendo assim, acredita-se na relevância de modelar a relação entre a classificação obtida a partir de julgamentos de inspeções e as características registradas das pontes, bem como sua relação, com a presença/ausência de insuficiência estrutural a partir das variáveis selecionadas.

O resultado encontrado a partir das relações obtidas entre as variáveis consideradas como significativas para a modelagem explicativa do julgamento de insuficiência estrutural no caso das pontes da Paraíba, reforça a reflexão, quanto ao número de pontes analisadas, quantidade de variáveis consideradas apropriadas e as

interações obtidas entre as variáveis para que se represente uma realidade específica de um grupo de pontes.

Tema este, explorado na literatura, na pesquisa de Lavrenz *et al.* (2020), que exploram como as considerações de interdependência podem melhorar avaliação do estado de condição das infraestruturas de pontes usando uma abordagem de regressão multivariada. O uso de modelos que compartilham interdependências entre variáveis pode fornecer informações mais precisas sobre o estado das pontes.

Bem como, o trabalho de Lu, Wang & Tolliver (2019), que propuseram uma abordagem de confiabilidade baseada em regressão logística ordinal para avaliar a precisão na previsão das classificações dos componentes da ponte e a concordância entre previsões e observações reais. Cinco critérios foram utilizados: erro de previsão, viés, precisão, previsões fora do intervalo, Critérios de Informação de Akaike (AIC) e log de verossimilhança (LL).

Outra questão levantada, é a utilização de metodologia parametrizada para desenvolver modelos mais precisos e adaptáveis, pois permite ajustar as previsões de acordo com as características específicas das pontes, como as consideradas no presente estudo. Esse tipo de abordagem possivelmente melhora a precisão das análises ao considerar variáveis específicas que afetam a degradação e o desempenho das estruturas, proporcionando uma modelagem mais flexível e alinhada com as características dos sistemas analisados.

4.1.2 Abordagem do julgamento da insuficiência estrutural a partir de algoritmos de *Machine learning*

Assim, em uma análise preliminar por meio da regressão logística se verificou que cinco variáveis seriam importantes para se efetuar as classificações quanto a insuficiência estrutural das pontes para a amostra considerada. É possível buscar algoritmos que levem em conta as mesmas variáveis para fornecer uma capacidade mais assertiva de classificação. Por essa razão decidiu-se por investigar a capacidade preditiva de outros cinco algoritmos, dentre aqueles muito usados em aprendizagem de máquina (*Machine Learning*), comparando-as com aquela da regressão logística.

A Tabela 26 mostra uma análise preliminar dos algoritmos de *Machine Learning*. Nessa tabela temos o tipo de algoritmo utilizado, as características (em termos de

parâmetro ou método) do algoritmo usado, a acurácia, a taxa de não informação, o coeficiente *Kappa* e o teste comparativo entre a taxa de não informação e a acurácia.

Tabela 26 - Comparação dos algoritmos

Algoritmo	Parâmetros	Acurácia (IC95%)	Taxa de Não informação	Kappa	Valor p do teste
Naive Bayes	-	0,8111 (0,7149; 0,8859)	75,56	0,51120	0,13360
Random Forest	n.árvores=10	0,8000 (0,7667; 0,8769)	76,67	0,47570	0,27130
Random Forest	n.árvores=20	0,8111 (0,7149; 0,8859)	80,00	0,48480	0,45800
Random Forest	n.árvores=30	0,8444 (0,7528; 0,9123)	74,44	0,60250	0,01639
Random Forest	n.árvores=40	0,8556 (0,7657; 0,9208)	80,00	0,60610	0,11520
kNN	k=5	0,8222 (0,7274; 0,8948)	81,11	0,50850	0,45750
kNN	k=6	0,8444 (0,7528; 0,9123)	78,89	0,58140	0,12030
kNN	k=7	0,8556 (0,7657; 0,9208)	80,00	0,60610	0,11520
Regressão logística	-	0,8444 (0,7528; 0,9123)	78,89	0,58140	0,12030
SVM	kernel linear	0,8222 (0,7274; 0,8948)	81,11	0,50850	0,45750
SVM	kernel polinomial	0,7222 (0,6178; 0,8115)	100,00	0,00000	1,00000
SVM	kernel radial	0,8222 (0,7274; 0,8948)	81,11	0,50850	0,45750
SVM	kernel sigmoide	0,7889 (0,6901; 0,8679)	86,67	0,37360	0,98599
MLP	100 neurônios; 1000 épocas; ativação racktfier	0,7889 (0,6901; 0,8679)	73,33	0,46730	0,14090
MLP	50 neurônios; 1000 épocas; ativação racktfier	0,8111 (0,7149; 0,8859)	71,11	0,53500	0,02085
MLP	20 neurônios; 1000 épocas; ativação racktfier	0,8222 (0,7274; 0,8948)	67,78	0,57770	0,00016
MLP	10 neurônios; 1000 épocas; ativação racktfier	0,8333 (0,7400; 0,9036)	71,11	0,58970	0,00540

Fonte: Autora (2023)

Pela Tabela 26 é possível verificar que apenas dois tipos de algoritmo de *Machine Learning* (os algoritmos *Random Forest* com 30 árvores e de redes neurais MLP com 50, 20 ou 10 neurônios na camada oculta) apresentaram diferenças significativas entre a acurácia e a taxa de não informação. A acurácia para o algoritmo de *Random Forest* foi

de 74,44%, o coeficiente de Kappa foi de 0,6025 (o que representa uma concordância substancial) e o valor p do teste de comparação da acurácia com a taxa de não informação foi 0,01639. Para o algoritmo Perceptron multicamadas observa-se que aquele com 10 neurônios na camada oculta foi o que apresentou o maior valor de acurácia (83,33%) e de coeficiente Kappa (0,5897). Nenhum dos demais algoritmos apresentou uma diferença significativa entre a acurácia e a taxa de não informação.

A taxa de não informação indica o percentual de acerto nas classificações se todos os registros forem classificados naquela classe dominante (aquela que mais ocorre). A comparação entre a acurácia e a taxa de não-informação (chamada de classificação ingênua) é importante porque uma maior assertividade pode ocorrer apenas porque há uma classe que é mais observada na amostra. Essa taxa é essencial quando há um desequilíbrio nos registros das classificações, como ocorre nesse estudo onde temos 27,58% das pontes classificadas como insuficientes estruturalmente e 72,42% como sendo suficientes. O valor p do teste comparativo da acurácia e da taxa de não informação pode indicar se a um ganho significativo no uso do algoritmo em relação a comparação pela classificação ingênua.

A Tabela 27 mostra as medidas de acurácia para cada um dos algoritmos em 30 repetições da validação cruzada com 10 *folds* (divisão da amostra em 10 partes iguais, onde 9 dessas partes são usadas no treinamento e uma das partes é usada no teste de validação).

Tabela 27 - Valores da acurácia a partir de 30 avaliações por *Cross-Validation* com 10 *folds*

Número de Repetições	Algoritmos usados					
	Naive Bayes	Random Forest	K-Nearest Neighbor	Regressão Logística	Support Vector Machine	Perceptron multicamadas
1	0,7400	0,8028	0,7998	0,7881	0,8115	0,8181
2	0,7403	0,7854	0,7926	0,7924	0,8069	0,8219
3	0,7471	0,8035	0,8027	0,7917	0,8058	0,8215
4	0,7434	0,7954	0,7949	0,8033	0,8103	0,8171
5	0,7430	0,7882	0,7911	0,7766	0,8100	0,8340
6	0,7325	0,8109	0,7848	0,7922	0,8219	0,8171
7	0,7473	0,8114	0,7846	0,7918	0,8103	0,8241
8	0,7397	0,7842	0,7992	0,7989	0,8110	0,8249
9	0,7394	0,7967	0,7921	0,7954	0,8060	0,8176
10	0,7432	0,7974	0,7884	0,7955	0,8110	0,8192
11	0,7433	0,8110	0,7846	0,7880	0,8153	0,8224
12	0,7471	0,7809	0,7810	0,8040	0,8070	0,8213

13	0,7404	0,7990	0,7806	0,7992	0,7996	0,8169
14	0,7439	0,8027	0,7990	0,7874	0,8105	0,8170
15	0,7437	0,7955	0,7953	0,7990	0,8067	0,8062
16	0,7438	0,7916	0,7891	0,7805	0,8070	0,8189
17	0,7436	0,8142	0,8136	0,7991	0,8067	0,8186
18	0,7364	0,7918	0,8074	0,7953	0,8074	0,8253
19	0,7401	0,8036	0,7960	0,8076	0,8111	0,8157
20	0,7439	0,7813	0,7837	0,7999	0,8076	0,8184
21	0,7472	0,7805	0,7918	0,7882	0,8028	0,8183
22	0,7439	0,7914	0,7836	0,8066	0,8106	0,8183
23	0,7360	0,7900	0,7994	0,7994	0,8137	0,8212
24	0,7434	0,8069	0,8030	0,8069	0,8068	0,8176
25	0,7432	0,7911	0,8031	0,7956	0,8063	0,8261
26	0,7365	0,8023	0,7997	0,7957	0,8107	0,8220
27	0,7435	0,8069	0,7888	0,7959	0,8106	0,8216
28	0,7402	0,7888	0,8036	0,7991	0,8090	0,8132
29	0,7517	0,7882	0,8017	0,7954	0,8148	0,8225
30	0,7429	0,7920	0,7801	0,7995	0,8149	0,8184

Fonte: Autora (2023)

No entanto, é importante utilizar métodos mais robustos de avaliação dos algoritmos. O uso repetido de vezes do método de validação cruzada é muito usado para avaliar e comparar os algoritmos. A Tabela 28 mostra a ordem crescente da acurácia das classificações dos algoritmos com base no método *Cross-Validation* em cada uma das 30 repetições. É possível notar que o algoritmo de redes neurais MLP é aquele que apresentou o melhor desempenho em quase todas as repetições, sendo seguida do algoritmo SVM.

Tabela 28 - Rank dos algoritmos pela acurácia


Número de Repetições	Algoritmos usados					
	Naive Bayes	Random Forest	K-Nearest Neighbor	Regressão Logística	Support Vector Machine	Perceptron multicamadas
1	6	3	4	5	2	1
2	6	5	3	4	2	1
3	6	3	4	5	2	1
4	6	4	5	3	2	1
5	6	4	3	5	2	1
6	6	3	5	4	1	2
7	6	2	5	4	3	1
8	6	5	3	4	2	1
9	6	3	5	4	2	1
10	6	3	5	4	2	1
11	6	3	5	4	2	1

12	6	5	4	3	2	1
13	6	4	5	3	2	1
14	6	3	4	5	2	1
15	6	4	5	3	1	2
16	6	3	4	5	2	1
17	6	2	3	5	4	1
18	6	5	3	4	2	1
19	6	4	5	3	2	1
20	6	5	4	3	2	1
21	6	5	3	4	2	1
22	6	4	5	3	2	1
23	6	5	4	4	2	1
24	6	3	5	2	4	1
25	6	5	3	4	2	1
26	6	2	4	5	3	1
27	6	3	5	4	2	1
28	6	5	3	4	2	1
29	6	5	4	4	2	1
30	6	4	5	3	2	1

Fonte: Autora (2023)

Para verificar se há diferenças significativas entre os algoritmos presentes na Tabela 28 quanto à acurácia das classificações utilizou-se o teste de Friedman e o teste de Nemenyi. Na Figura 15 pelo teste verificou-se uma distância crítica de 1,337. O teste de Friedman sugere que há diferenças entre pelo menos dois dos algoritmos.

Figura 15 - Representação gráfica do teste de Friedman e o teste de Nemenyi



Fonte: Autora (2023)

Desse modo, na Figura 19 observou-se que entre os algoritmos SVN e MLP o valor obtido foi $(2,13 - 1,07 = 1,06 < 1,337)$, o que seria indiferente utilizar qualquer um destes para formular cenários baseados em previsões. Verificou ainda que existem três grupos de algoritmos semelhantes em termos de capacidade de predição. O KNN, a regressão logística e o *Random Forest*; estes também tiveram desempenhos semelhantes

em termos de capacidade de predição. Na Tabela 29 temos valores das estatísticas de Kappa.

Tabela 29 - Valores da estatística Kappa resultante de 30 avaliações por cross-validation com 10 folds

Número de Repetições	Algoritmos usados					
	Naive Bayes	Random Forest	K-Nearest Neighbor	Regressão Logística	Support Vector Machine	Perceptron multicamadas
1	0,1415	0,4798	0,4466	0,4127	0,4902	0,5173
2	0,1446	0,4310	0,4108	0,3928	0,4650	0,5236
3	0,1770	0,4708	0,4533	0,4149	0,4630	0,5188
4	0,1453	0,4799	0,4233	0,4459	0,4654	0,5025
5	0,1489	0,4452	0,4373	0,3655	0,4781	0,5458
6	0,1328	0,4962	0,4155	0,4224	0,5191	0,5134
7	0,1796	0,4906	0,4040	0,4040	0,4845	0,5317
8	0,1408	0,4414	0,4507	0,4231	0,4907	0,5335
9	0,1436	0,4697	0,4421	0,3968	0,4675	0,5157
10	0,1622	0,4682	0,4184	0,4264	0,4851	0,5161
11	0,1585	0,5174	0,3972	0,4112	0,5036	0,5045
12	0,1724	0,4217	0,3962	0,4324	0,4688	0,5174
13	0,1521	0,4828	0,3937	0,4372	0,4627	0,5085
14	0,1510	0,4891	0,4536	0,3969	0,4858	0,5126
15	0,1579	0,4580	0,4416	0,4368	0,4727	0,4852
16	0,1607	0,4613	0,4202	0,3700	0,4718	0,5285
17	0,1515	0,5097	0,4733	0,4218	0,4608	0,5126
18	0,1376	0,4658	0,4678	0,4282	0,4732	0,5378
19	0,1336	0,4737	0,4509	0,4614	0,4892	0,5027
20	0,1591	0,4233	0,4020	0,4326	0,4767	0,5186
21	0,1732	0,4394	0,4193	0,3988	0,4567	0,5188
22	0,1652	0,4501	0,3764	0,4544	0,4891	0,5205
23	0,1336	0,4502	0,4462	0,4221	0,5097	0,5076
24	0,1620	0,4935	0,4626	0,4461	0,4704	0,5094
25	0,1640	0,4394	0,4723	0,4212	0,4659	0,5448
26	0,1321	0,4788	0,4323	0,4128	0,4847	0,5249
27	0,1551	0,4854	0,4170	0,4214	0,4777	0,5198
28	0,1345	0,4539	0,4569	0,4399	0,4700	0,5023
29	0,1911	0,4475	0,4580	0,4090	0,5068	0,5212
30	0,1596	0,4552	0,3998	0,4379	0,5030	0,5110

Fonte: Autora (2023)

Observando o coeficiente *Kappa* para as repetições do treinamento e teste, observa-se que todos os valores para aquele algoritmo com melhor desempenho se

apresentaram no intervalo entre 0,4 e 0,6, o que indica uma concordância moderada com as classificações observadas com a pesquisa de campo.

Os resultados aqui explanados corroboram com a literatura, pois em diversas pesquisas na área de infraestrutura, especificamente em pesquisas com o foco no estado de condição de pontes, exploração de dados de relatórios de inspeção como suporte adicional na avaliação de riscos, modelos de deterioração, entre outros, foram encontradas modelagens a partir de (ML) *Machine Learning*, que incluem (NB) Naïve Bayes, Árvores de Decisão (DT), k-Vizinhos Mais Próximos (k-NN), regressão logística (LR) e *Support Vector Machines* (SVM). Estas modelagens alcançaram precisões variando de 49,11% a 91,12%, e em outros o desempenho dos modelos alcançaram 97% de acerto e 84% de precisão (CALDAS *et al.*, 2002; KIM, 2021; JOOTOO; LATTANZI, 2017; LI *et al.*, 2021; ALIPOUR *et al.*, 2017, OZYÜKSEL ÇİFTÇİOĞLU; NASER, 2024).

No trabalho de Caldas *et al.* (2002) foi desenvolvido um sistema automatizado para classificar documentos com base em seu conteúdo, usando técnicas de *Machine learnig* para facilitar a gestão de grandes volumes de informações. Na primeira fase, algoritmos e sistemas de classificação de aprendizado de máquina foram analisados e avaliados. As ferramentas utilizadas para esse fim foram *Support Vector Machines* (SVMs), algoritmo *Rocchio*, Naive Bayes, K-nearest neighbors e IBM Miner para Texto.

No estudo de Li *et al.* (2021), temos uma classificação automatizada de condições, com vistas ao controle de qualidade de dados a partir de relatórios de inspeções de pontes, nessa pesquisa foram identificadas e agrupadas as variáveis, em tipo de material, sistema construtivo, deficiência estrutural e localização da ponte de acordo com faixas estabelecidas. Cinco sistemas de *Machine Learnig* (ML) foram usados, *Naïve Bayes* (NB), *Decision Tree* (DT), *k-Nearest Neighbors* (k-NN), Regressão logística e *Support Vector Machine* (SVM) para analisar descrições textuais de inspeções de pontes e transformá-las em classificações quantitativas de condição. Desse modo, eles alcançaram uma precisão de 88,67% nas classificações de condições.

Ozyüksel Çiftçioğlu & Naser (2024), abordam a análise de dados observacionais para determinar as causas e os efeitos das falhas em pontes. A análise causal partiu de dados observacionais de quase 299 incidentes em pontes, a partir de técnicas avançadas de *Machine Learning* para avaliar o desempenho de pontes críticas. Esta abordagem permitiu a exploração de cenários contra factuais e forneceu informações valiosas sobre a resiliência das infraestruturas.

Desse modo, na tese em destaque obteve-se uma melhora na precisão e acurácia para inferir sobre o julgamento da insuficiência estrutural a partir dos pareceres de inspetores quanto as características da ponte com algoritmos *Machine Learning*. Os valores alcançados na tese em destaque, foi de 74,44% para o *Random Forest* e no Perceptron Multicamadas com 10 neurônios na camada oculta foi apresentou o maior valor de acurácia (83,33%). Reitera-se a importância do uso de ferramentas de *machine learning* para estudos de sistemas complexos, como as pontes. Técnicas estatísticas tradicionais, apesar de úteis, podem não capturar completamente as nuances causais em sistemas complexos.

Alipour *et al.* (2017) abordaram o uso de técnicas de *Machine Learning* para avaliar a capacidade de uma carga de populações de pontes. O principal objetivo foi utilizar os algoritmos de classificação, *Decision tree and Random forest*, para classificar e avaliar a capacidade de carga de diferentes pontes. Isso visou melhorar a precisão e eficiência na avaliação da condição estrutural das pontes. De igual modo, os resultados alcançados aqui também integraram métodos de *Machine Learning*, os quais permitiram uma avaliação detalhada e precisa na modelagem proposta. Seguiu-se assim as tendências de estudos atuais segundo a literatura, quanto ao uso integrado de das técnicas tradicionais de avaliação, estas identificam os padrões e verificam as relações das variáveis dependentes com as independentes. E as técnicas mais robustas para melhorar as previsões.

Alipour & Harris (2021), afirma que a aplicação de algoritmos de *machine learning* permite identificar padrões que métodos tradicionais não conseguem identificar. Embora em muitos contextos, na abordagem de machine learning, a capacidade de combinar vários algoritmos para obter reconhecimentos de padrões adicionais (em relação a métodos tradicionais) ocorra, sua vantagem em relação a métodos tradicionais de regressão consiste na possibilidade de melhoria da precisão de predições.

4.1.3 Abordagem do julgamento da insuficiência estrutural a partir de Redes Bayesianas Discretas

Em um primeiro momento, foram definidos os nós na rede a partir de um conjunto de variáveis resultantes do processo de seleção *Stepwise Backward* aplicado a um modelo de regressão logística binomial. As variáveis inicialmente usadas na regressão logística


foram aquelas oriundas de relatórios de inspeções realizadas nos anos de 2019 e 2020 no Estado da Paraíba. Nesse caso foram consideradas as avaliações do estado de condição realizadas pelos inspetores para o grupo de pontes do referido estudo.

Posteriormente, verificou-se para o conjunto de variáveis selecionadas um grupo de restrições para os arcos pai e filho, considerando aquelas relações que se apresentavam inconsistentes com o contexto de realidade do problema. As restrições que foram definidas apresentam duas naturezas:

- *Black list* - as relações condicionais que eram inconsistentes com o contexto da realidade do problema;
- *White list* – as relações condicionais presumidas com base na experiência da pesquisadora

Dadas as restrições dos relacionamentos entre os nós, utilizou-se o algoritmo de *Hill-Climbing* para obter um grafo da rede considerando como critério o valor do AIC. O grafo selecionado é mostrado na Figura 16.

Figura 16 - Gráfico usado na rede bayesiana discreta



Fonte: elaborado pela autora, 2024.

A partir da Figura 20, observa-se primeiramente que o julgamento sobre a insuficiência estrutural das pontes está condicionado a idade da ponte, ao tipo de estrutura, a largura da pista e a presença de duas patologias, que são o concreto desagregado e deslocamento. No entanto, a presença das duas patologias está condicionada a idade da ponte, ao tipo de estrutura e largura da pista. Portanto, a avaliação da insuficiência estrutural está diretamente e indiretamente condicionada a idade da ponte, a largura da

pista e ao tipo de estrutura. Há, portanto também outras razões pela qual esses três nós pai condicionam a avaliação, que não são apenas porque por contribuírem para ocorrência de concreto desagregado ou para o fenômeno do deslocamento.

A estimação das tabelas de probabilidade condicionadas (CPT) foi realizada por meio do método da máxima verossimilhança. Com o objetivo de analisar se a hipótese de independência condicional poderia ser rejeitada para as relações entre os nós da rede utilizou-se o teste χ^2 e o teste *Mutual Information*. Considerando um nível de significância igual a 0,05 é possível rejeitar a hipótese de independência condicional para os arcos considerados na rede, o que indica que as relações indicadas na rede apresentam sustentação empírica (corrobora com as associações observadas nos dados levantados).

4.2. MODELAGEM EXPLICATIVA DA NOTA ATRIBUÍDA AO ESTADO DE CONDIÇÃO E AS CARACTERÍSTICAS REGISTRADAS DAS PONTES

Nesse item é apresentado um procedimento de avaliação da nota atribuída às pontes com a obtenção de um modelo regressivo que permita explicar a relação entre as notas atribuídas pelos inspetores e as características registradas das pontes. O procedimento de avaliação é iniciado identificando variáveis mais importantes para explicar os pareceres dos avaliadores com base em uma análise preliminar usando a regressão logística ordinal. A Tabela 30 apresenta informações do processo de seleção *Stepwise Backward* para um modelo de regressão logística ordinal com a nota atribuída como variável independente.

Tabela 30 - Processo *Stepwise Backward* para a regressão logística Ordinal

Etapa	AIC	Número de características	Característica excluída do modelo
1	-2,18	-	Trem Tipo
2	-4,00	11	Largura da ponte
3	-5,43	10	Presença de manchas de umidade
4	-7,00	9	Infiltração
5	-7,16	8	Presença de lixiviação e mancha de carbonatação
6	-7,17	7	Juntas danificadas

7	-3,77	6	Comprimento da ponte
---	-------	---	----------------------

Fonte: Autora (2024)

Ainda sobre a Tabela 30, nesse tipo de modelo a intenção é explicar uma variável dependente ordinal. O procedimento de seleção indicou que seis das onze variáveis deveriam ser mantidas no modelo selecionado. Para o modelo resultante do processo de seleção das variáveis, a Tabela 31 apresenta as estimativas e o intervalo de confiança para razão da chance do modelo, bem como sua significância com base no teste de Wald.

Tabela 31- Variáveis selecionadas pelo Stepwise

Característica	Odds Ratio	IC95%	z	p
Presença de deslocamento de concreto com armadura exposta				
Não	-	-	-	-
Sim	0,47	(0,294; 0,740)	-3,24	0,0012
Presença de concreto desagregado com armadura exposta e oxidada				
Não	-	-	-	-
Sim	0,24	(0,136; 0,422)	-4,93	<0,0001
Presença de oxidação do ferro				
Não	-	-	-	-
Sim	0,09	(0,043; 0,182)	-6,62	<0,0001
Idade da ponte				
Após 1985	-	-	-	-
1975 -1985	1,09	(0,607; 1,953)	0,29	0,7748
1960 - 1975	9,99	(3,563; 28,016)	4,38	<0,0001
Até 1960	3,55	(1,069; 11,831)	-2,07	0,0385
Largura da pista (em metros)	0,92	(0,728; 1,168)	-0,67	0,5023
Tipo de estrutura				
Viga de Concreto Armado	-	-	-	-
Outros	3,69	(2,084; 6,550)	4,47	<0,0001

Fonte: Autora (2024)

Uma das variáveis selecionadas (a largura da ponte) não apresentou estimativas significativas. Além da largura da ponte, um dos coeficientes associados à idade da ponte também não apresentou significância.

4.2.1 Abordagem explicativa da nota atribuída do estado de condição a partir da regressão logística ordinal

Na Tabela 32 é possível perceber que todos os parâmetros se apresentam como significativos se a idade da OAE for excluída do modelo. Sem essa variável a largura da pista passou a apresentar um coeficiente associado significativo. Observa-se que a presença de deslocamento de concreto com armadura exposta tende a reduzir a chance de ocorrer notas mais altas em 53% ($0,47 = 1 - 0,53$). Considerando uma margem de erro, essa redução tende a ser entre 26,4% ($0,736 = 1 - 0,264$) e 70,3% ($0,297 = 1 - 0,703$). A presença de concreto desagregado com armadura exposta oxidada tende a reduzir a chance de ocorrência de notas mais altas em 80% ($0,20 = 1 - 0,80$). Levando em consideração uma margem de erro essa redução tende a ser entre 64,8% ($0,352 = 1 - 0,648$) e 88,1% ($0,119 = 1 - 0,881$).

Tabela 32 - Modelo I

Característica	Odds Ratio	IC95%	z	p
Presença de deslocamento de concreto com armadura exposta				
Não	-	-	-	-
Sim	0,47	(0,297; 0,736)	-3,28	0,0010
Presença de concreto desagregado com armadura exposta e oxidada				
Não	-	-	-	-
Sim	0,20	(0,119; 0,352)	-5,73	<0,0001
Presença de oxidação do ferro				
Não	-	-	-	-
Sim	0,08	(0,042; 0,171)	-6,86	<0,0001
Largura da pista (em metros)	1,20	(1,067; 1,344)	3,06	0,0022

Tipo de estrutura				
Viga de Concreto Armado	-	-	-	-
Outros	2,86	(1,673; 4,909)	3,83	0,0001

Fonte: Autora (2024)

Também a partir da Tabela 32 percebeu-se que a observação pelo avaliador da presença de oxidação do ferro tende a reduzir a chance de avaliar com notas mais altas em 92% ($0,08 = 1 - 0,92$). Considerando uma margem de erro é possível admitir que essa redução seja de até 95,8% ($0,958 = 1 - 0,042$). Já o aumento da largura da pista tende a aumentar as chances de atribuição de uma nota mais alta. Para cada metro adicional na largura da pista tende a aumentar em 20% (1,20) a chance de atribuir uma nota mais alta.

Um modelo alternativo que também contém apenas parâmetros significativos podem ser obtidos ao desconsiderar no modelo a largura da pista e agrupando duas classes da idade da OAE (de modo que esse agrupamento expresse todas as unidades com idade superior a 1975). As estimativas de razão da chance, intervalos de confiança e significâncias dos parâmetros são mostradas na Tabela 33.

Tabela 33 - Modelo II acrescido da idade da ponte				
Característica	Odds Ratio	IC95%	z	p
Presença de deslocamento de concreto com armadura exposta				
Não	-	-	-	-
Sim	0,47	(0,297; 0,740)	-3,25	0,0010
Presença de concreto desagregado com armadura exposta e oxidada				
Não	-	-	-	-
Sim	0,25	(0,140; 0,431)	-4,90	<0,0001
Presença de oxidação do ferro				
Não	-	-	-	-
Sim	0,09	(0,044; 0,184)	-6,59	<0,0001
Idade da ponte				
Após 1975	-	-	-	-
1960 – 1975	7,92	(3,675;17,067)	5,28	<0,0001

Até 1960	2,42	(1,417; 4,158)	3,23	0,0012
Tipo de estrutura				
Viga de Concreto Armado	-	-	-	-
Outros	3,69	(2,095; 6,490)	3,83	0,0001

Fonte: Autora (2024)

Visto que dois modelos alternativos contendo apenas parâmetros significativos foram observados considerando as seis variáveis resultantes do processo de seleção *Stepwise Backward*, esses modelos foram comparados utilizando duas métricas de avaliação. Na Tabela 34 temos a comparação entre os modelos I e II.

Tabela 34 - Avaliação da acurácia e AUC por classe da variável dependente

Classe da variável dependente	Modelo I		Modelo II	
	AUC	Acurácia	AUC	Acurácia
1	0,837	0,922	0,834	0,953
2	0,78	0,779	0,759	0,763
3	0,682	0,565	0,668	0,538
4	0,86	0,752	0,824	0,749

Fonte: Autora (2024)

As métricas de avaliação, por serem aplicadas a um modelo com uma variável dependente ordinal, se referem a capacidade de classificar corretamente para cada classe da variável dependente, que é a nota atribuída. Em geral, os valores da área abaixo da curva ROC e a acurácia apresentam valores maiores para o modelo I.

4.3 MODELO DE REDES BAYESIANAS DISCRETAS PARA AVALIAÇÃO DA NOTA ATRIBUÍDA

Para investigar a importância das inter-relações (entre características das OAE, entre as patologias e das características com as patologias) na atribuição das notas aplicou-se um modelo de redes bayesianas considerando apenas aquelas selecionadas utilizando o processo de seleção *stepwise* com a regressão. Seis variáveis foram selecionadas e utilizadas como nós no grafo da rede. Definidos os nós utilizou-se o

algoritmo de Hill-Climbing para obter um modelo de rede parcimonioso (menor número de arcos e mais assertivo) com base na estatística AIC.

Esse algoritmo permite otimizar a medida de parcimônia (o AIC) considerando restrições quanto aos arcos que obrigatoriamente devem estar presentes e aqueles que não devem ocorrer na rede. As restrições quanto aos arcos que devem estar presentes na rede considerou apenas relações de todas as variáveis com a nota geral. Essas restrições foram impostas porque foi admitido como pressuposto que pelo menos as relações identificadas no modelo de regressão logística ordinal deveriam ser consideradas.

Além das restrições dos arcos que deveriam estar presentes, considerou-se também pressupostos de um conjunto de arcos que não deveriam fazer parte da rede. Em geral, essas restrições eram referentes a arcos direcionados das patologias para as características das OAE ou entre as características. Essas são relações que são incoerentes e não poderiam existir na rede.

Aplicado o algoritmo de Hill Climbing, o grafo resultante foi utilizado juntamente com os dados dos nós selecionados para estimar as probabilidades condicionadas usando o método da máxima verossimilhança. Como resultado obteve a rede bayesiana composta pelo grafo final e pelas tabelas de probabilidades condicionadas (CPT).

Para verificar se os arcos presentes nas redes, de fato, deveriam ser mantidos, foram aplicados testes de hipótese e independência condicional. Dois testes de hipótese foram aplicados: o teste χ^2 de Pearson e o teste *Mutual Information*. A hipótese nula desses testes é de que há independência condicional entre os nós ligados pelos arcos especificados. Os resultados dos testes para cada um dos arcos são apresentados na Tabela 35. Observa-se dos 12 arcos analisados, apenas 2 indicavam ligações onde não foi rejeitada a hipótese de independência condicional.


Tabela 35 - Testes de independência condicional na rede bayesiana

Nós		Teste χ^2 de Pearson		Teste Mutual Information	
		Estatística	valor p	Estatística	valor p
Idade da ponte	Presença de deslocamento	31,21	0,0000007695395	32,27	0,000000459006
Idade da ponte	Presença de concreto desagregado	29,38	0,0000018621604	27,24	0,000005242737
Idade da ponte	Nota Geral	63,39	0,0000000002966	65,58	0,000000000111
Largura da pista	Presença de deslocamento	33,72	0,0000000475433	33,91	0,000000043359
Largura da pista	Nota Geral	41,77	0,0000002041693	40,77	0,000000321868
Tipo de Estrutura	Presença de oxidação do ferro	2,93	0,0869660038933	3,39	0,065729400382
Tipo de Estrutura	Nota Geral	30,28	0,0000012057956	41,14	0,000000006096
Presença de deslocamento	Presença de oxidação do ferro	7,99	0,0047119815253	7,57	0,005919395573
Presença de deslocamento	Presença de concreto desagregado	8,97	0,0027417864231	9,59	0,001955067235
Presença de deslocamento	Nota Geral	36,86	0,0000000492332	40,53	0,000000008208
Presença de oxidação do ferro	Presença de concreto desagregado	1,56	0,2110650969539	1,70	0,191941011275
Presença de concreto desagregado	Nota Geral	61,36	0,0000000000003	58,97	0,000000000001

Fonte: Autora (2024)

Na Figura 17, podem ser vistas que essas relações são entre tipo de estrutura e oxidação do ferro exposto, e entre essa patologia e o concreto desagregado. Os dois testes usados indicaram que havia independência condicional nesses dois arcos.

Figura 17 - Rede bayesiana para nota atribuída




Fonte: Autora (2024)

Portanto, observadas que essas relações, que resultariam em uma ligação indireta da oxidação do ferro exposto com a nota atribuída pelo avaliador, não eram significativas então o nó referente oxidação do ferro foi desconsiderada na obtenção da rede. Novamente o algoritmo de Hill Climbing foi usado para obter um grafo e as tabelas de probabilidades condicionadas foram novamente estimadas.

O gráfico resultante está presente na Figura 18, onde é possível identificar relações condicionais diretas e indiretas das características das OAE. A presença do deslocamento possui apenas relações condicionais diretas com a nota atribuída. A presença de concreto desagregado apresenta relações condicionais com a presença de deslocamento, de modo que tem relações diretas e indiretas com a nota geral atribuída.

Figura 18 - Rede bayesiana para nota atribuída excluindo a oxidação do ferro



Fonte: Autora (2024)

4.4 CENÁRIOS HIPOTÉTICOS

A partir dos algoritmos treinados considerou-se uma amostra de 20 cenários hipotéticos definidos pelas características e patologias das pontes presentes nos modelos. Dadas as configurações dessas variáveis, obteve-se a classificação quanto ao julgamento da insuficiência estrutural e notas atribuídas pelos inspetores. O objetivo da formulação dos cenários foi identificar os padrões pelos quais as características e patologias são utilizadas para inferir sobre o parecer da condição geral da ponte nesse contexto na perspectiva do avaliador.

4.4.1 Julgamento esperado no parecer dos avaliadores é examinado com base em um modelo de regressão logística binomial

Na Tabela 36 são apresentados cenários hipotéticos de OAE por meio da especificação de características e patologias. O julgamento esperado no parecer dos avaliadores é examinado com base em um modelo de regressão logística binomial. No quadro, a

avaliação esperada é mostrada por meio da estimativa de probabilidade de julgar como estruturalmente insuficiente uma OAE e por meio de uma classificação resultante da comparação dessa probabilidade com o ponto de corte definido a partir da curva ROC (0,5514). As OAE cuja probabilidade estimada pelo modelo é superior ao ponto de corte são classificadas como apresentando insuficiência estrutural.

Observa-se pelo modelo que a observação das duas patologias resultou, considerando apenas os cenários avaliados, necessariamente em julgamentos de insuficiência estrutural. Também é percebido que a ausência das duas patologias necessariamente é acompanhada pelo julgamento de que não há insuficiência estrutural. As outras duas características podem estar associadas ao julgamento quando apenas uma das patologias está presente.

No entanto, para os 20 cenários avaliados é possível notar que, quando apenas uma das patologias está presente, o julgamento como estruturalmente insuficiente ocorreu apenas quando era característica da OAE a inauguração antes de 1975. A distinção da inauguração entre 1975 e 1985 e após 1985 teve pouca relevância no julgamento das OAE. Também não se identificou qualquer associação nos 20 cenários observados do tipo de estrutura da viga. Dentre as pontes que apresentam apenas uma das duas patologias há julgamentos de insuficiência estrutural tanto em casos onde a viga era de concreto quanto nos casos onde a viga era de outro material. Portanto, apenas com base nesses cenários não é informativo para entender esse julgamento observar o tipo de material da viga. De qualquer modo, é importante ter cautela sobre a importância dessa informação porque nem todas as combinações de características possíveis foram investigadas com os cenários.

Tabela 36 - Avaliação do parecer de insuficiência estrutural nos cenários pela regressão logística binomial

Cenários	Presença de deslocamento	Presença de concreto desagregado	Idade da OAE	Tipo de estrutura da OAE	Probabilidade de julgar com insuficiência estrutural	Parecer se há insuficiência estrutural
1	Sim	Sim	Entre 1975 e 1985	Viga de concreto	0,79	Sim
2	Sim	Sim	Antes de 1975	Viga de outro material	0,92	Sim
3	Sim	Sim	Após 1985	Viga de outro material	0,80	Sim
4	Sim	Sim	Entre 1975 e 1985	Viga de concreto	0,79	Sim
5	Sim	Sim	Após 1985	Viga de outro material	0,80	Sim
6	Não	Não	Entre 1975 e 1985	Viga de outro material	0,08	Não
7	Não	Não	Entre 1975 e 1985	Viga de outro material	0,08	Não
8	Não	Não	Após 1985	Viga de concreto	0,30	Não
9	Não	Não	Antes de 1975	Viga de concreto	0,55	Não
10	Não	Não	Após 1985	Viga de concreto	0,30	Não
11	Não	Sim	Após 1985	Viga de concreto	0,68	Sim
12	Não	Sim	Antes de 1975	Viga de concreto	0,86	Sim
13	Não	Sim	Antes de 1975	Viga de outro material	0,74	Sim
14	Não	Sim	Entre 1975 e 1985	Viga de concreto	0,47	Não
15	Não	Sim	Antes de 1975	Viga de outro material	0,74	Sim
16	Sim	Não	Antes de 1975	Viga de concreto	0,83	Sim
17	Sim	Não	Antes de 1975	Viga de outro material	0,70	Sim
18	Sim	Não	Antes de 1975	Viga de outro material	0,70	Sim
19	Sim	Não	Entre 1975 e 1985	Viga de concreto	0,42	Não
20	Sim	Não	Após 1985	Viga de outro material	0,45	Não

Fonte: Autora (2024)

4.4.2 Parecer esperado investigados utilizando um dos algoritmos que apresentaram o melhor desempenho na abordagem de machine learning

Na Tabela 37 as OAE dos cenários tiveram o parecer esperado investigados utilizando um dos algoritmos que apresentaram o melhor desempenho na abordagem de *Machine Learning*. Como mostrado, as medidas de avaliação não tiveram diferenças significativas entre os algoritmos de *Support Vector Machine* (SVM) e Redes Neurais Artificiais Perceptron Multicamadas, de modo que se considerou indiferente a escolha entre esses métodos preditivos. As classificações presentes no quadro 2 foram obtidas usando o algoritmo SVM.

Algumas informações observadas foram semelhantes aquelas realizadas a partir da Tabela 36, que se refere a avaliação dos cenários com regressão logística ordinal. Na Tabela 37 é possível também notar que a presença das duas patologias utilizadas na aplicação do algoritmo SVM necessariamente resultou em julgamento de insuficiência estrutural, levando em conta apenas a observação dos 20 cenários. Também foi observado que a ausência das duas patologias é acompanhada necessariamente do julgamento de que não há insuficiência estrutural nesses cenários.

A observação de que OAE com uma das duas patologias tendem a ser julgadas como estruturalmente insuficientes quando teve inauguração antes de 1975 também ocorreu para aplicação do algoritmo SVM. Em todos os cenários onde há uma patologia e a OAE foi inaugurada antes de 1975 a classificação do julgamento pelo algoritmo foi de insuficiência estrutural. No entanto, em cenários onde apenas uma das patologias é observada, a inauguração após 1975 não garante que o julgamento seja de que não há insuficiência estrutural. A Tabela 37 há um dos cenários onde apenas há apenas deslocamento e, mesmo com a inauguração após 1985, o algoritmo classifica que há insuficiência estrutural. Portanto, uma investigação com mais cenários pode necessária para entender casos como nesse cenário e também para compreender melhor como o tipo de estrutura da viga informa sobre o julgamento esperado.

Tabela 37 - Avaliação do parecer de insuficiência estrutural nos cenários pelo algoritmo de *Support Vector Machine* (SVM)

Cenários	Presença de deslocamento	Presença de concreto desagregado	Idade da OAE	Tipo de estrutura da OAE	Parecer se há insuficiência estrutural
1	Sim	Sim	Entre 1975 e 1985	Viga de outro material	Sim
2	Sim	Sim	Após 1985	Viga de outro material	Sim
3	Sim	Sim	Antes de 1975	Viga de concreto	Sim
4	Sim	Sim	Após 1985	Viga de concreto	Sim
5	Sim	Sim	Entre 1975 e 1985	Viga de concreto	Sim
6	Não	Não	Antes de 1975	Viga de concreto	Não
7	Não	Não	Após 1985	Viga de outro material	Não
8	Não	Não	Antes de 1975	Viga de outro material	Não
9	Não	Não	Após 1985	Viga de concreto	Não
10	Não	Não	Após 1985	Viga de concreto	Não
11	Não	Sim	Entre 1975 e 1985	Viga de outro material	Não
12	Não	Sim	Entre 1975 e 1985	Viga de concreto	Não
13	Não	Sim	Entre 1975 e 1985	Viga de outro material	Não
14	Não	Sim	Antes de 1975	Viga de concreto	Sim
15	Não	Sim	Antes de 1975	Viga de outro material	Sim
16	Sim	Não	Após 1985	Viga de concreto	Sim
17	Sim	Não	Antes de 1975	Viga de outro material	Sim
18	Sim	Não	Antes de 1975	Viga de outro material	Sim
19	Sim	Não	Antes de 1975	Viga de outro material	Sim
20	Sim	Não	Entre 1975 e 1985	Viga de concreto	Não

Fonte: Autora (2024)

4.4.3 a avaliação do julgamento de insuficiência estrutural a partir da rede bayesiana

A Tabela 38 mostra a avaliação do julgamento de insuficiência estrutural a partir da rede bayesiana. Embora, a rede tenha sido informativa sobre as inter-relações, os cenários apresentaram divergências até mesmo sobre a avaliação de OAE quando há as duas patologias ou quando não há patologias. Nesses casos o algoritmo SVM e a regressão logística indicou com clareza que o julgamento esperado seria de insuficiência estrutural quando havia as duas patologias e que não haveria quando nenhuma das duas patologias foi observada. A rede bayesiana discreta não mostrou na investigação dos cenários, capacidade de efetuar esse diagnóstico. Portanto, é preciso ter cautela ao usar esse tipo de algoritmo.

É importante lembrar que o algoritmo *naive bayes* é baseado em um modelo de rede bayesiana discreta. Esse algoritmo teve o pior desempenho na análise de validação cruzada (*cross validation*), logo era esperado que o desempenho não fosse bom na análise dos cenários.

Tabela 38 - Avaliação do parecer de insuficiência estrutural nos cenários pelas redes bayesianas

Cenários	Presença de deslocamento	Presença de concreto desagregado	Idade da OAE	Intervalo da largura da pista	Tipo de estrutura da OAE	Probabilidade de julgar com insuficiência estrutural	Parecer se há insuficiência estrutural
1	Sim	Sim	Entre 1975 e 1985	(5,59;8]	Viga de concreto	0,47	Não
2	Sim	Sim	Antes de 1975	(5,59;8]	Viga de outro material	0,47	Não
3	Sim	Sim	Após 1985	(5,59;8]	Viga de outro material	0,86	Sim
4	Sim	Sim	Entre 1975 e 1985	(5,59;8]	Viga de concreto	0,43	Não
5	Sim	Sim	Após 1985	(5,59;8]	Viga de outro material	0,78	Sim
6	Não	Não	Entre 1975 e 1985	(5,59;8]	Viga de outro material	0,80	Sim
7	Não	Não	Entre 1975 e 1985	(8;10,4]	Viga de outro material	1,00	Sim
8	Não	Não	Após 1985	(8;10,4]	Viga de concreto	0,93	Sim
9	Não	Não	Antes de 1975	(8;10,4]	Viga de concreto	0,93	Sim
10	Não	Não	Após 1985	(8;10,4]	Viga de concreto	0,93	Sim
11	Não	Sim	Após 1985	(8;10,4]	Viga de concreto	0,94	Sim
12	Não	Sim	Antes de 1975	(8;10,4]	Viga de concreto	0,92	Sim
13	Não	Sim	Antes de 1975	(8;10,4]	Viga de outro material	0,94	Sim
14	Não	Sim	Entre 1975 e 1985	(8;10,4]	Viga de concreto	0,92	Sim
15	Não	Sim	Antes de 1975	(10,4;12,8]	Viga de outro material	0,62	Sim
16	Sim	Não	Antes de 1975	(10,4;12,8]	Viga de concreto	0,90	Sim
17	Sim	Não	Antes de 1975	(10,4;12,8]	Viga de outro material	0,87	Sim
18	Sim	Não	Antes de 1975	(10,4;12,8]	Viga de outro material	0,90	Sim
19	Sim	Não	Entre 1975 e 1985	(10,4;12,8]	Viga de concreto	0,90	Sim
20	Sim	Não	Após 1985	(10,4;12,8]	Viga de outro material	0,32	Não

Fonte: Autora (2024)

A Tabela 39 mostra a avaliação dos cenários sob a perspectiva da nota atribuída pelo avaliador. Utilizou-se um modelo de regressão logística ordinal para estimar a probabilidade de escolha de cada uma das notas de acordo com as características e patologias. A classificação quanto à nota atribuída foi obtida a partir da comparação das probabilidades. A nota cuja probabilidade associada foi a maior foi aquela escolhida como parecer esperado.

O modelo de regressão logística ordinal aplicado para avaliar os 20 cenários sugere que a probabilidade de escolha da nota 4 é baixa para maior parte dos cenários. Daqueles avaliados, apenas em três a probabilidade de escolha da nota 4 foi a segunda maior. No entanto, em nenhum desses cenários seria essa uma nota atribuída. Portanto, há uma tendência dos avaliadores não atribuírem a nota 4, e as notas que tendem a ser mais presentes são 1, 2 e 3.

Também houve clareza que a presença das três patologias selecionadas no modelo tende a levar à atribuição da nota mais baixa pelos avaliadores. Se nenhuma das patologias é identificada a nota 1 não é atribuída. Porém, nos cenários investigados não se verificou clareza na escolha entre notas 2 e 3 quando nenhuma patologia estava presente. Quando apenas duas das patologias estavam presentes, o modelo também indicou uma tendência de escolha entre as notas 2 e 3.

Sobre a relação da largura da pista e do tipo de estrutura da viga com a atribuição das notas, não foi possível observar padrões com base nos cenários. Portanto, seria importante observar um número maior de cenários para entender melhor a relação dessas características com a nota.

Tabela 39 - a avaliação dos cenários sob a perspectiva da nota atribuída pelo avaliador

Cenário	Largura da pista (em metros)	Presença de deslocamento	Presença de oxidação do ferro	Presença de concreto desagregado	Tipo de estrutura da viga	Probabilidades de julgamento das notas				Nota esperada
						Nota = 1	Nota = 2	Nota = 3	Nota = 4	
1	8,98	Sim	Sim	Sim	Viga de concreto	0,71	0,27	0,02	0,00	1
2	7,55	Sim	Sim	Sim	Viga de outro material	0,49	0,45	0,05	0,00	1
3	8,89	Sim	Sim	Sim	Viga de concreto	0,71	0,26	0,02	0,00	1
4	10,77	Sim	Não	Sim	Viga de concreto	0,15	0,60	0,22	0,02	2
5	8,92	Sim	Não	Sim	Viga de outro material	0,07	0,49	0,39	0,05	2
6	8,57	Não	Não	Não	Viga de outro material	0,01	0,10	0,54	0,35	3
7	10,61	Não	Sim	Não	Viga de concreto	0,17	0,61	0,20	0,02	1
8	9,86	Não	Sim	Não	Viga de concreto	0,18	0,61	0,19	0,02	1
9	6,71	Não	Sim	Não	Viga de outro material	0,09	0,55	0,33	0,04	1
10	7,39	Não	Não	Não	Viga de concreto	0,02	0,26	0,57	0,14	2
11	9,55	Não	Não	Sim	Viga de outro material	0,03	0,33	0,53	0,11	2
12	9,40	Não	Não	Sim	Viga de outro material	0,03	0,33	0,53	0,11	2
13	9,49	Não	Sim	Sim	Viga de concreto	0,52	0,43	0,05	0,00	1
14	10,36	Não	Sim	Sim	Viga de outro material	0,26	0,60	0,13	0,01	2

15	9,34	Não	Sim	Sim	Viga de outro material	0,28	0,59	0,12	0,01	2
16	8,20	Sim	Não	Não	Viga de outro material	0,02	0,20	0,59	0,20	3
17	9,18	Sim	Não	Não	Viga de outro material	0,01	0,19	0,59	0,21	3
18	8,74	Sim	Não	Não	Viga de concreto	0,04	0,39	0,49	0,08	3
19	7,07	Sim	Não	Não	Viga de concreto	0,05	0,42	0,46	0,07	3
20	10,25	Sim	Não	Não	Viga de concreto	0,04	0,36	0,51	0,09	3

Fonte: Autora (2024)

5. CONCLUSÕES E RECOMENDAÇÕES

5.1. DIVERSAS MODELAGENS PARA A DETERIORAÇÃO DAS OAES

A investigação realizada serviu para mostrar que existem diversos modelos de deterioração de pontes, porém, o desenvolvimento de processos matemático e estatisticamente válidos não significa, necessariamente, a representação da realidade. Nesse sentido, percebe-se que esse campo de estudo ainda necessita de aprofundamentos, com o intuito de contornar as deficiências existentes, ou seja, fazer modelos capazes de uma representação holística, considerando os diversos aspectos relacionados ao processo de deterioração das estruturas.

É importante estar ciente que em vários casos as limitações possivelmente, ocorrem, dentre outros fatores, devido à insuficiência de registros regulares de inspeções, como no caso do Brasil. De acordo com Canãmares (2016), o processo de deterioração em uma ponte tem um importante componente aleatório e outro mais previsível baseado na observação, comum a problemas de alta complexidade, a qual resulta na combinação de um grande número de parâmetros, cuja conexão causa-efeito ainda se está longe de saber na sua totalidade.

5.2 ESTADO DE CONDIÇÃO DAS OAES

No intuito de contribuir para a avaliação de pontes, foi desenvolvida a abordagem aqui apresentada a partir de um contexto específico de um grupo de pontes do estado da Paraíba; do qual foi possível perceber várias questões. A primeira foi em relação aos dados disponíveis de SGO/DNIT, estes irregulares, com lacunas consideráveis, por exemplo, em informações de Trem-tipo e idade das pontes. O formato, PDF, em que são disponibilizados os relatórios também dificulta a catalogação das informações detalhadas das inspeções, por exemplo, muitos termos sem padronização, gerando dúvidas para a catalogação dos dados.

Em relação ao estado de condição das pontes da Paraíba, percebeu-se que havia algumas inconsistências nas avaliações, a partir do julgamento de inspetores. Por exemplo, uma ponte recebia nota 1, que é a pior condição em um ciclo de inspeção; no próximo ciclo a mesma ponte sem aparentemente ter passado por manutenção, tinha uma

melhora em sua nota. A subjetividade presente em todo o processo de inspeção possivelmente contribui para que isso aconteça. Esse é um tema recorrente na literatura, algumas pesquisas procuram contribuir nesse sentido, empregando mecanismos de controle qualidade para as avaliações (BUCHHEIT *et al.*, 2005; DIN; TANG, 2016; CHEN *et al.*, 2005; MIGLIACCIO *et al.*, 2014; OZYÜKSEL ÇİFTÇIOĞLU; NASER, 2024; ALIPOUR *et al.* 2017; WANG *et al.*, 2024).

As informações contidas nos relatórios de inspeção de pontes apresentam uma oportunidade para melhorar a qualidade da avaliação das condições. Além disso, um certo controle poderia ser adotado em tempo real para que o julgamento dos inspetores em campo, quanto ao estado de condição fosse mais assertivo. Os relatórios são uma base de conhecimento que agrega a experiência de inspetores e, portanto, poderiam ser usados para apoiar no julgamento das classificações de condições, tornando-as mais consistentes.

Nesse sentido, esta tese buscou uma ferramenta auxiliar para tentar parametrizar a avaliação de insuficiência estrutural, tendo em vista que a partir dos relatórios foi possível identificar as variáveis envolvidas neste tipo de avaliação e gerar padrões, para que mais tarde, fosse possível identificar inconsistências no julgamento da insuficiência estrutural. Bem como, a influência das características selecionadas desse grupo de ponte na atribuição da nota para o estado de condição geral da ponte. A parametrização é vista na literatura, como um caminho para diminuir a subjetividade (GOYAL *et al.*, 2017; RUCK; FRANCIS, 2017; HUANG, 2006; SRIKANTH; AROCKIASAMY, 2020; LIU; EL-GOHARY, 2020).

5.3 MODELAGEM EXPLICATIVA

5.3.1 Modelo logístico para explicar o julgamento de insuficiente estrutural

O estudo efetuou o levantamento de um conjunto de características das pontes e de avaliações realizadas por especialistas sobre a insuficiência estrutural das pontes. De doze características presentes no estudo, identificou-se cinco como sendo as mais importantes no contexto do grupo de pontes estudadas: presença de deslocamento de concreto com armadura exposta; presença de concreto desagregado com armadura exposta e oxidada; largura da pista; tipo de estrutura e idade da ponte. Com os dados relativos a essas cinco variáveis foi obtido um modelo de regressão logística para explicar o julgamento de uma ponte como insuficiente estruturalmente. O modelo logístico

apresentou um bom ajuste, tendo indicado a correta classificação para 82,73% dos registros investigados e apresentando uma área abaixo da curva ROC (AUC) igual a 0,8314.

5.3.2 Adequação de diferentes métodos preditivos para o julgamento de insuficiência estrutural

Efetuuou-se também uma investigação da adequação de diferentes métodos preditivos. Os algoritmos *naive bayes*, *random forest*, regressão logística, *k-nearest neighbours*, *support vector machine* e redes neurais perceptron multicamadas foram treinados considerando 75% da amostra e a validação foi testada para 25% restante do grupo do estudo.

Embora, maior parte dos algoritmos aplicados ao problema tenham apresentado valores de acurácia superiores a 0,8 e coeficiente Kappa indicando uma concordância moderada ou substancial em relação aos julgamentos realizados pelos especialistas, as taxas de não informação (percentual de acertos ao julgar todos os registros como estruturalmente suficientes, que era a classe dominante) se apresentaram altas. Para maior parte dos algoritmos não se verificou um ganho significativo na assertividade das classificações em comparação aquelas realizadas pelo método “ingênuo” (expressa pela taxa de não informação). Apenas os algoritmos *random forest* e redes neurais perceptron multicamadas apresentam ganhos significativos dependendo de valores dos seus parâmetros.

Por meio do método de validação cruzada aplicado repetidamente 30 vezes, observou-se medidas de acurácia próximos de 0,80 para todos os algoritmos usados, exceto para o método *naive bayes* (que apresentou muitas vezes acurácias inferiores a 0,75). O coeficiente Kappa apresentou para quase todas as aplicações do método *cross-validation* valores entre 0,4 e 0,6 (também excetuando-se o método *naive bayes*), sugerindo uma capacidade preditiva moderada.

Dentre os métodos considerados na avaliação preditiva da insuficiência estrutural, os algoritmos de redes neurais perceptron multicamadas (*Multi Layer Perceptron* - MLP) e *support vector machine* (SVM) foram aqueles que se apresentaram mais vezes nas duas melhores posições comparativas do desempenho. Em uma etapa posterior, verificou-se que havia diferenças significativas entre pelo menos um dos algoritmos e os demais em termos de capacidade preditiva considerando o teste de Friedman. Pelo teste de Nemenyi

observou que não havia diferenças significativas no desempenho dos algoritmos SVM e MLP, mas houve desses com os demais.

No entanto, visto que numa etapa preliminar o ganho de informação foi significativo para o MLP, recomenda-se que para avaliação de pontes em um contexto semelhante ao do grupo estudado uma predição adequada das avaliações sobre insuficiência estrutural pode ser obtida usando o método de redes neurais perceptron multicamadas considerando 10 neurônios na camada oculta, com 1000 épocas e usando como função de ativação a *rectifier* (que foram as características usadas no algoritmo na etapa de validação pelo método *cross-validation*).

5.3.3 Modelo logístico ordinal para explicar a nota atribuída ao estado de condição

No modelo logístico ordinal as variáveis selecionadas (*stepwise backward*) para a modelagem foram: deslocamento de concreto com armadura exposta; concreto desagregado com armadura exposta e oxidada; oxidação do ferro; idade da ponte; largura da pista e tipo de estrutura. As melhores taxas de acerto foram nas classificações para as notas 1 (92,2%) e 2 (78,0%). A boa qualidade do ajuste dos modelos de regressão logística foi um indicativo de que seria possível formular um modelo com uma capacidade preditiva suficiente para auxiliar nas classificações das pontes quanto a sua insuficiência estrutural e no julgamento das notas de condição.

5.3.4 Geração de Cenários

Por fim, a partir dos algoritmos avaliou-se 20 cenários onde se observou o papel preponderante dos danos de deslocamento de concreto com armadura exposta e concreto desagregado com armadura exposta e oxidada, para o julgamento de insuficiência estrutural e para a atribuição das notas de condição. A estimativa contra factual permite explorar cenários hipotéticos e avaliar o impacto de intervenções ou mudanças em variáveis. Usando dados observados, simula-se resultados alternativos para avaliar efeitos causais específicos (YANG *et al.*, 2021). Isso envolve elaborar um modelo que represente a estrutura causal subjacente e estime cenários contra factuais (HENNE *et al.*, 2019), oferecendo uma forma confiável e interpretável de prever resultados sob diferentes condições.

No campo da infraestrutura, mais precisamente em se tratando de dados oriundo da inspeção de pontes tem-se vários desafios a serem superados. A começar pela procedência dos dados, estes, que por sua vez deveriam se confiáveis e oriundos de uma coleta rigorosa. Vale ressaltar, que já existem revisões de técnicas de coleta de dados de pontes e algoritmos analíticos, no entanto a discussão sobre o gerenciamento de dados é menos abordada. Tais questões, por exemplo, necessidades de dados, armazenamento e compartilhamento são fundamentais para direcionar o processo de tomada de decisão.

Nesse sentido tem-se novas abordagens e direcionamentos para as futuras pesquisas, tais como: propor métodos quantitativos de verificação da qualidade dos registros para a avaliação das pontes. Uso de imagens de satélite para verificação do estado de condições da ponte. Há também uma falta de acesso automático às fontes de dados. O acesso automático aos bancos de dados dos SGOs não está bem estabelecido, como tal, muitos métodos analíticos não podem ser implementados na prática, uma vez que é impraticável manualmente pesquisar dados e repetir a pesquisa quando os dados forem atualizados. Desse modo, pesquisas que desenvolvam técnicas de automatização para a coleta de dados dos relatórios de inspeção seriam de grande valia.

5.4 DIFICULDADES ENCONTRADAS E PRINCIPAL CONTRIBUIÇÃO

Destaque-se, que uma das grandes dificuldades encontradas na construção dessa tese, foi justamente a quantidade de tempo empreendida na coleta de dados. Desse modo, reconhece-se a necessidade de modelagens de mineração de dados, tendo em vista que facilitaria a extração automática de informações dos relatórios de inspeção. Bem como, ajudaria no reconhecimento de inconsistências no processo de inspeção.

A principal contribuição desse trabalho foi metodológica, destacando-se 4 partes: 1) seleção das variáveis com vistas a um modelo parcimonioso e estimação dos efeitos das características das pontes e patologias sobre o julgamento da insuficiência estrutural e nota atribuída pelos inspetores; 2) melhoria da capacidade preditiva pelo treinamento e comparação de diferentes algoritmos de machine learning; 3) investigação da importância das inter-relações entre as variáveis independentes para compreensão do processo decisório da avaliação das pontes; 4) reforço do entendimento da relação dos julgamentos dos inspetores com as características das pontes e patologias selecionadas através da observação de cenários hipotéticos analisados usando os métodos preditivos usados.

5.5 RECOMENDAÇÕES PARA TRABALHOS FUTUROS E LIMITAÇÕES

A mesma abordagem realizada nesta pesquisa, poderia ser realizada com vista ao estudo das deficiências funcionais, e sua relação com as características das pontes, bem como com a nota atribuída ao estado de condição geral das pontes. Vale ressaltar, que as mesmas modelagens aplicadas as pontes da paraíba poderão ser replicadas a nível nacional. E possivelmente trarão novas percepções acerca do comportamento das pontes em contextos mais abrangente, nacional. Bem como, em outros contextos, resguardados os devidos ajustes; desde que estejam disponíveis as informações das características das infraestruturas e os danos relacionados ao julgamento de insuficiência estrutural e atribuição das notas de condição.

As limitações encontradas na pesquisa, estão destacadas em 4 pontos: 1) foram consideradas apenas as estruturas do estado da Paraíba, uma vez que o acesso ao banco de dados do SGO ocorreu de maneira tardia, inviabilizando em termos logísticos a catalogação de um número maior de pontes para o estudo. 2) o recorte temporal foi limitado (2019-2020). 3) não foram consideradas a severidade dos danos e nem a localização destes nos elementos das pontes e 4) não foram considerados fatores ambientais. Os pontos citados anteriormente também podem ser entendidos como melhorias a serem realizadas para os próximos estudos.

REFERÊNCIAS BIBLIOGRÁFICAS

AASHTO. **Guide Manual for Bridge Element Inspection**. 2011.

AASHTO. **LRFD Bridge Design Specifications Customary U.S. Units**. 2012

AASHTO. **Manual for Bridge Element Inspection (MBEI)**. 2nd Ed., 2019.

ABNT - ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NB 6**: Cargas móveis em pontes rodoviárias. Rio de Janeiro, 1960.

ABNT - ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 7188**: Carga móvel rodoviária e de pedestres em pontes, viadutos, passarelas e outras estruturas. Rio de Janeiro, 2013.

ABNT - ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 9452**: Vistorias de Pontes e Viadutos de Concreto. Associação Brasileira de Normas Técnicas. 3. ed. Rio de Janeiro, 2016.

AKGÜL, F.; FRANGOPOL, D. M. Time-dependent interaction between load rating and reliability of deteriorating bridges. **Engineering Structures**, 2004. v. 26, n. 12, p. 1751–1765.

ALIPOUR, M., HARRIS, D. K., BARNES, L. E., OZBULUT, O. E., & CARROLL, J. (2017). Load-capacity rating of bridge populations through machine learning: Application of decision trees and random forests. **Journal of Bridge Engineering**, 22(2), 04016106. [https://doi.org/10.1061/\(ASCE\)BE.1943-5592.0001103](https://doi.org/10.1061/(ASCE)BE.1943-5592.0001103).

ALMEIDA, A. T. **Processo de decisão nas organizações: construindo modelos de decisão multicritério**. São Paulo: Atlas, 2013.

ALSHARQAWI, M.; ZAYED, T.; ABU DABOUS, S. Integrated condition rating and forecasting method for bridge decks using Visual Inspection and Ground Penetrating Radar. **Automation in Construction**, 2018. v. 89, n. February, p. 135–145. <https://doi.org/10.1016/j.autcon.2018.01.016>.

American Road and Transportation Builders Association (ARTBA). **ARTBA Bridge Report**. 2020. Disponível em: <https://artbabridgereport.org/reports/2020%20ARTBA%20Bridge%20Report.pdf>. Acesso em: 7 abr. 2021.

AM-STR-06054. EIRSPAN Bridge Management System Principal Inspection Manual. Transport Infrastructure Ireland. February, 2017.

AM-STR-06055. EIRSPAN Bridge Management System Principal Inspection Manual. Transport Infrastructure Ireland. February, 2017.

ASCE - AMERICA SOCIETY OF CIVIL ENGINEERS. **Report Card of America's Infrastructure** (2017). Disponível em: <https://www.infrastructurereportcard.org/cat->

[item/bridges/](#). Acesso em: 7 abr. 2021.

BAKÓ, A.; GÁSPÁR, L. Development of a sustainable optimization model for the rehabilitation of transport infrastructure. **Acta Polytechnica Hungarica**, 2018. v. 15, n. 1, p. 11–33.

BALOMENOS, GEORGIOS P.; KAMESHWAR, SABARETHINAM; PADGETT, Jamie E. Parameterized fragility models for multi-bridge classes subjected to hurricane loads. **Engineering Structures**, v. 208, 2020. <https://doi.org/10.1016/j.engstruct.2020.110213>.

BAO, Yuequan; CHEN, Zhicheng; WEI, Shiyin; XU, Yang; TANG, Zhiyi; LI, Hui. The State of the Art of Data Science and Engineering in Structural Health Monitoring. **Engineering**, v. 5, n. 2, p. 234–242, 2019. DOI: [10.1016/j.eng.2018.11.026](https://doi.org/10.1016/j.eng.2018.11.026).

BJÖRNSSON, I. *et al.* Decision support framework for bridge condition assessments. **Structural Safety**, 2019. v. 81, p. 101874. <https://doi.org/10.1016/j.strusafe.2019.101874>.

BRANCO, H. A. P. Colapsos de pontes: Lições aprendidas. **Dissertação**. 2013. Lisboa.

BU, G. *et al.* Development of an integrated method for probabilistic bridge-deterioration modeling. **Journal of Performance of Constructed Facilities**, 2014. v. 28, n. 2, p. 330–340.

BU, G. *et al.* Long-term performance of bridge elements using integrated deterioration method incorporating elman neural network. **Applied Mechanics and Materials**, 2012. v. 204–208, p. 1980–1987.

BUCHHEIT, R. B.; GARRETT JR., J. H.; MCNEIL, S.; CHEN, P. Automated procedure to assess civil infrastructure data quality: method and validation. **Journal of Infrastructure Systems**, v. 11, p. 180–189, 2005. [https://doi.org/10.1061/\(ASCE\)1076-0342\(2005\)11:3\(180\)](https://doi.org/10.1061/(ASCE)1076-0342(2005)11:3(180)).

C. IACOVINO, TURKSEZER, Z. I., P. F. GIORDANO, AND M. P. LIMONGELLI. (2022). “Comparison of Bridge Inspection Policies in terms of Data Quality.” **J. Bridge Eng.**, 27(3): 04021115. [https://doi.org/10.1061/\(ASCE\)BE.1943-5592.0001831](https://doi.org/10.1061/(ASCE)BE.1943-5592.0001831).

CALDAS, C. H., SOIBELMAN, L., & HAN, J. (2002). Automated classification of construction project documents. **Journal of Computing in Civil Engineering**, 16(4), 234–243. [https://doi.org/10.1061/\(ASCE\)0887-3801\(2002\)16:4\(234\)](https://doi.org/10.1061/(ASCE)0887-3801(2002)16:4(234)).

CALLOW, D. *et al.* Development of hybrid optimisation method for Artificial Intelligence based bridge deterioration model - Feasibility study. **Automation in Construction**, 2013. v. 31, p. 83–91. <http://dx.doi.org/10.1016/j.autcon.2012.11.016>.

CALVERT, G. *et al.* Modelling interactions between multiple bridge deterioration mechanisms. **Engineering Structures**, 2020b. v. 221, n. May, p. 111059. <https://doi.org/10.1016/j.engstruct.2020.111059>.

CALVERT, G. *et al.* Multi-defect modelling of bridge deterioration using truncated inspection records. **Reliability Engineering and System Safety**, 2020a. v. 200, n. March, p. 106962. <https://doi.org/10.1016/j.ress.2020.106962>.

CAÑAMARES, J. M. Universidad Politécnica De Madrid Escuela Técnica Superior De Ingenieros De Caminos, Canales Y Puertos Departamento Mecánica De Medios Continuos Y Teoría De Estructuras. **Tese**. [S.l.]: Universidad Politécnica de Madrid, 2016. Disponível em: http://oa.upm.es/39436/1/Javier_Martinez_Canamares.pdf>. Acesso em: 7 abr. 2021.

CAVALLINE, T. L. *et al.* Determination of Bridge Deterioration Models and Bridge User Costs for the NCDOT Bridge Management System. 2015. n. October, p. 188. **Report**. Disponível em: <https://connect.ncdot.gov/projects/planning/RNAProjDocs/2014-07FinalReport.pdf>>. Acesso em: 10 mar. 2022.

CHEN, L. *et al.* Multiobjective optimization for maintenance decision making in infrastructure asset management. **Journal of Management in Engineering**, 2015. v. 31, n. 6, p. 1–9.

CHEN, L.; BAI, Q. Optimization in decision making in infrastructure asset management: A review. **Applied Sciences (Switzerland)**, 2019. v. 9, n. 7.

CHEN, P.; BUCHHEIT, R. B.; GARRETT JR., J. H.; MCNEIL, S. Web-vacuum: web-based environment for automated assessment of civil infrastructure data. **Journal of Computing in Civil Engineering**, v. 19, p. 137–147, 2005. [https://doi.org/10.1061/\(ASCE\)0887-3801\(2005\)19:2\(137\)](https://doi.org/10.1061/(ASCE)0887-3801(2005)19:2(137)).

CHENG, Y.; MELHEM, H. G. Monitoring bridge health using fuzzy case-based reasoning. **Advanced Engineering Informatics**, 2005. v. 19, n. 4, p. 299–315.

COSTIN, A. *et al.* Building Information Modeling (BIM) for transportation infrastructure – Literature review, applications, challenges, and recommendations. **Automation in Construction**, 2018. v. 94, n. July, p. 257–281. <https://doi.org/10.1016/j.autcon.2018.07.001>.

CRONOS QUALITY. PCP02: Etapas de um Modelo de Previsão. **Cronos Quality**, 2016. Disponível em: <https://trid.trb.org/view/1405296%0Ahttps://connect.ncdot.gov/projects/research/RNAProjDocs/2014-07FinalReport.pdf>>. Acesso em: 01 de maio de 2020.

DEPARTMENT FOR REGIONAL DEVELOPMENT NORTHERN IRELAND. **Design Manual for Roads and Bridges - Highway structures: Inspection and Maintenance. BD 63/07**. Volume 3, Section 1, Part 4. 2007.

DEPARTMENT FOR REGIONAL DEVELOPMENT NORTHERN IRELAND. **Design Manual for Roads and Bridges - Highway structures: Inspection and Maintenance. BD 63/17**. Volume 3, Section 1, Part 4. 2007.

DEUS, E.P. Análise do processo de fraturamento em vigas de pontes de aço sob efeito de fadiga, Ph.D. **Tese**. Universidade de São paulo, Escola de Engenharia de São Carlos.

Brasil (1997).

DIN, Z. U.; TANG, P. Automatic logical inconsistency detection in the national bridge inventory. **Procedia Engineering**, v. 145, p. 729–737, 2016. <https://doi.org/10.1016/j.proeng.2016.04.093>.

DNIT – DEPARTAMENTO NACIONAL DE INFRAESTRUTURA E TRANSPORTE. **Minuta do Manual de Manutenção de Obras de Artes Especiais – OAEs**. Brasília. 2016.

DNIT – DEPARTAMENTO NACIONAL DE INFRAESTRUTURA E TRANSPORTE. **NBR 010/2004 – PRO: Inspeções em Pontes e Viadutos de Concreto Armado e Protendido – Procedimento**. Departamento Nacional de Infraestrutura de Transportes. Rio de Janeiro, 2004.

DNIT – DEPARTAMENTO NACIONAL DE INFRAESTRUTURA E TRANSPORTE. **PNCT - Plano Nacional de Contagem de Tráfego**. Disponível em: <http://servicos.dnit.gov.br/dadospnct/ContagemContinua>. Acesso em: 27 de jan. 2020

DUPRÉ, J. **Puentes, la história de los puentes más famosos e importantes Del mundo**. Alemanha: Konemann, 2000.

DURANGO-COHEN, P. L. A time series analysis framework for transportation infrastructure management. **Transportation Research Part B: Methodological**, 2007. v. 41, n. 5, p. 493–505.

DURANGO-COHEN, P. L.; MADANAT, SAMER, M. Optimization of inspection and maintenance decisions for infrastructure facilities under performance model uncertainty: A quasi-Bayes approach. **Transportation Research Part A: Policy and Practice**, 2008. v. 42, n. 8, p. 1074–1085.

ELLIS; THOMPSON; GAGNON; RICHARD. Design and implementation of a new bridge management system for the Quebec Ministry of Transport. **Tenth International Conference on Bridge and Structure Management**. 2008.

ELSHAZLI, KHALED; ABDALLAH, AHMED; KHALIL, ALI; KALAYCI, NIHAT; MOHAMED, MOHAMED; EL-MAHDY, MOHAMED. Advancing Infrastructure Resilience: Machine Learning-Based Prediction of Bridges' Rating Factors Under Autonomous Truck Platoons. **Journal of Infrastructure Preservation and Resilience**, v. 5, n. 5, 2024. <https://doi.org/10.1186/s43065-024-00096-x>.

FHWA – FEDERAL HIGHWAY ADMINISTRATION. **Bridge Preservation Guide: Maintaining a State of Good Repair Using Cost Effective Investment Strategies**. U.S. Department of transportation. August, 2011.

FHWA – FEDERAL HIGHWAY ADMINISTRATION. **Bridge Preservation Guide: Maintaining a State of Good Repair Using Cost Effective Investment Strategies**. U.S. Department of transportation. August, 2011.

FHWA – FEDERAL HIGHWAY ADMINISTRATION. **Bridge Inspector's Reference Manual**. U.S. Department of transportation. December, 2012.

FHWA – FEDERAL HIGHWAY ADMINISTRATION. **Recording and Coding Guide for the Structure Inventory and Appraisal of the Nation's Bridges**. FHWA-PD-96–001 December, 1995.

FHWA – FEDERAL HIGHWAY ADMINISTRATION. **Underwater Bridge Inspection Manual**, FHWA-NHI-10–027, Pre-Publication Edition, 2010.

FHWA – FEDERAL HIGHWAY ADMINISTRATION. **Underwater Bridge Repair, Rehabilitation, and Countermeasures Manual**, FHWA-NHI-10–029, Pre-Publication Edition, 2010.

FIROUZI, A.; RAHAI, A. An integrated ANN-GA for reliability based inspection of concrete bridge decks considering extent of corrosion-induced cracks and life cycle costs. **Scientia Iranica**, 2012. v. 19, n. 4, p. 974–981. <http://dx.doi.org/10.1016/j.scient.2012.06.002>.

GHODOOSI, F.; ABU-SAMRA, S.; *et al.* Maintenance cost optimization for bridge structures using system reliability analysis and genetic algorithms. **Journal of Construction Engineering and Management**, 2018. v. 144, n. 2, p. 1–10.

GHODOOSI, F.; BAGCHI, A.; *et al.* Method for developing and updating deterioration models for concrete bridge decks using GPR data. **Automation in Construction**, 2018. v. 91, n. June 2017, p. 133–141. <https://doi.org/10.1016/j.autcon.2018.03.014>.

GIOVANNETTI, A. C. V. P. Avaliação do Estado de Conservação de Pontes – Estudo de Caso. **Dissertação**. Florianópolis, SC. 2014.

GOMES, C.; ROCHA, E.; VITÓRIO, A. Análise dos danos estruturais da ponte sobre o Rio Desterro localizada na BR-101/PE. *In*: XIII Congresso Internacional sobre Patologia e Reabilitação de Estruturas, CINPAR, 2017, Crato. **Anais [...]**. Crato.

GOYAL, R.; WHELAN, M. J.; CAVALLINE, T. L. Characterising the effect of external factors on deterioration rates of bridge components using multivariate proportional hazards regression. **Structure and Infrastructure Engineering**, 2017. v. 13, n. 7, p. 894–905. <http://dx.doi.org/10.1080/15732479.2016.1217888>.

GOYAL, R.; WHELAN, M. J.; CAVALLINE, T. L. Multivariable Proportional Hazards-Based Probabilistic Model for Bridge Deterioration Forecasting. **Journal of Infrastructure Systems**, 2020. v. 26, n. 2, p. 1–17.

GUTKOWSKI, RICHARD M; ARENELLA, NICHOLAS D. **Investigation of PONTIS - A Bridge Management Software**. Department of Civil Engineering. Colorado State University. 1998.

HACHEM, Y.; ZOGRAFOS, K.; SOLTANI, M. Bridge inspection strategies. **Journal of Performance of Constructed Facilities**, 1991. v. 5, n. 1, p. 37–56.

Handbook for Bridge Inspections – guidelines (part 1). Norwegian Public Roads Administration. Norway, 2005.

Handbook for Bridge Inspections – guidelines (part 2). Norwegian Public Roads Administration. Norway, 2005.

HASER H.; POHL S.; KASCHNER R. **Richtlinie zur Tragfähigkeitseinstufung bestehender Straßenbrücken der neuen Bundesländer in Lastklassen nach DIN 1072.** Der Bundesminister für Verkehr Abteilung Straßenbau. Berlin, 1992.

HATAMI, A.; MORCOUS, George. Deterministic and Probabilistic Lifecycle Cost Assessment: Applications to Nebraska Bridges. **Journal of Performance of Constructed Facilities**, 2016. v. 30, n. 2.

HAWK, H. BRIDGIT: user-friendly approach to bridge management. **TRB Transportation Research Circular** 498, p. 1–15, 1999.

HEITNER, B. *et al.* Updating probabilities of bridge reinforcement corrosion using health monitoring data. **Engineering Structures**, 2019. v. 190, n. March, p. 41–51. <https://doi.org/10.1016/j.engstruct.2019.03.103>.

HENG, J. *et al.* Dynamic Bayesian network-based system-level evaluation on fatigue reliability of orthotropic steel decks. **Engineering Failure Analysis**, 2019. v. 105, n. April, p. 1212–1228. <https://doi.org/10.1016/j.engfailanal.2019.06.092>.

HENRIKSEN, A. Bridge Management - Routine Maintenance: Recent Experience with the Routine Management Module in the DANBRO Bridge Management System. **Transportation Research Circular**, v. 498, p. 1–13, 1999.

Highway Structures & Bridges Inspection & Assessment - **CS 450 Inspection of highway structures.** Published by Highways England.2020.

Highway Structures & Bridges Inspection & Assessment - **CS 454 Assessment of highway bridges and structures.** Published by Highways England.2020.

Highway Structures & Bridges Inspection & Assessment - **CS 462 Repair and management of deteriorated concrete highway structures.** Published by Highways England.2020.

HONG, G. *et al.* Modelling long-term bridge deterioration at structural member level using Artificial Intelligence techniques. **Applied Mechanics and Materials**, 2011. v. 99–100, p. 444–453.

HUANG, R. Y. A performance-based bridge LCCA model using visual inspection inventory data. **Construction Management and Economics**, 2006. v. 24, n. 10, p. 1069–1081.

INKOOM, S. *et al.* Bridge health index: Study of element condition states and importance weights. **Transportation Research Record**, 2017. v. 2612, p. 67–75.

INKOOM, S.; SOBANJO, J. (2018). Availability function as bridge element's importance weight in computing overall bridge health index. **Structure and Infrastructure Engineering**, 14(12), 1598–1610.

IVANKOVIĆ, A. M.; SKOKANDIĆ, D.; ŽNIDARIČ, A.; KRESLIN, M. Bridge Performance Indicators Based on Traffic Load Monitoring. **Structure and Infrastructure Engineering**, vol. 15, no. 7, 899–911. 2019.

JIANG, Y. Application and Comparison of Regression and Markov Chain Methods in Bridge Condition Prediction and System Benefit Optimization. **Journal of the Transportation Research Forum**, 2010. v. 49, n. 2, p. 91–110.

JOOTOO, A., & LATTANZI, D. (2017). *Bridge type classification: Supervised learning on a modified NBI data set*. **Journal of Computing in Civil Engineering**, 31(6), 04017063. [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000712](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000712)

KAZANTZI, ATHANASIA K.; MOUTSIANOS, SOKRATIS; BAKALIS, KONSTANTINOS; MITOULIS, STERGIOS-ARISTOTELES. Cause-agnostic Bridge Damage State Identification Utilising Machine Learning. **Engineering Structures**, v. 320, 2024. <https://doi.org/10.1016/j.engstruct.2024.118887>.

KIM, H.; TAE, S.; AHN, Y.; YANG, J. Scenarios for life cycle studies of bridge concrete structure maintenance. **Sustainability**, v. 12, n. 22, p. 9557, 2020.

KIM, N.; HONG, S. (2021). Automatic classification of citizen requests for transportation using deep learning: Case study from Boston city. **Information Processing & Management**, 58(1), 102410. <https://doi.org/10.1016/j.ipm.2020.102410>.

KIM, Y. J.; QUEIROZ, L. B. Big Data for Condition Evaluation of Constructed Bridges. **Engineering Structures**, 2017. v. 141, p. 217–227. <http://dx.doi.org/10.1016/j.engstruct.2017.03.028>.

KOBBACY, K. A. H. Application of Artificial Intelligence in Maintenance Modelling and Management. **IFAC Proceedings Volumes (IFAC-PapersOnline)**, 2012. v. 45, n. 31, p. 54–59.

KUHN, K. D.; MADANAT SAMER, M. Model Uncertainty and the Management of a System of Infrastructure Facilities. **Transportation Research Part C: Emerging Technologies**, 2005. v. 13, n. 5–6, p. 391–404.

LANTZ, Brett. Machine Learning with R. Birmingham: **Packt Publishing**, 2013. 396 p. ISBN 978-1-78216-214-8.

LAVRENZ, S. M.; SAEED, T. U.; MURILLO-HOYOS, J.; VOLOVSKI, M.; LABI, S. (2020). Can Interdependency Considerations Enhance Forecasts of Bridge Infrastructure Condition? Evidence Using a Multivariate Regression Approach. **Structure and Infrastructure Engineering**, 16(8), 1177–1185. <https://doi.org/10.1080/15732479.2019.1693606>

LEE, J. *et al.* Improving the reliability of a Bridge Management System (BMS) using an ANN-based Backward Prediction Model (BPM). **Automation in Construction**, 2008. v. 17, n. 6, p. 758–772.

LEE, J. *et al.* Refinement of backward prediction method for reliable artificial intelligence-based bridge deterioration modelling. **Advances in Structural Engineering**, 2012. v. 15, n. 5, p. 825–836.

LEISTMEISTER, Cory. Mastering Machine Learning with R. **Packt Publishing**, 2015. 386 p. ISBN 978-1-78398-452-7

LI, J. Q.; MCNEIL, S. Data envelopment analysis for highway asset investment assessment. **Journal of Traffic and Transportation Engineering (English Edition)**, 2019. n. xxx, p. 1–12. <https://doi.org/10.1016/j.jtte.2019.06.001>.

LI, M.; JIA, G. Bayesian Updating of Bridge Condition Deterioration Models Using Complete and Incomplete Inspection Data. **Journal of Bridge Engineering**, 2020. v. 25, n. 3, p. 04020007.

LI, TIANSHU; ALIPOUR, MOHAMAD; HARRIS, DEVIN K. Mapping textual descriptions to condition ratings to assist bridge inspection and condition assessment using hierarchical attention. **Automation in Construction**, v. 129, 2021.

LIU, K.; EL-GOHARY, N. (2020). Fusing data extracted from bridge inspection reports for enhanced data-driven bridge deterioration prediction: A hybrid data fusion method. **Journal of Computing in Civil Engineering**, 34(6), 4020047. [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000921](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000921).

LIU, M.; FRANGOPOL, D. M. Optimal bridge maintenance planning based on probabilistic performance prediction. **Engineering Structures**, 2004. v. 26, n. 7, p. 991–1002.

LOPES, J. M.; BOGÉA, M.; REBELLO, Y. **Arquiteturas da engenharia ou engenharias da arquitetura**. São Paulo: Mandarim, 2006.

LÓPEZ, C. E. N. Desenvolvimento de metodologia sistemática para a avaliação do estado das pontes existentes no Brasil. [s.l.] Universidade Estadual de Campinas Faculdade de Engenharia Civil, Arquitetura e Urbanismo. **Dissertação**. 2020.

LOUNIS, Z.; MADANAT, S. M. Integrating mechanistic and statistical deterioration models for effective bridge management. **Proceedings of the International Conference on Applications of Advanced Technologies in Transportation Engineering**, 2002. p. 513–520.

LRPC CLERMONT-FERRAND *et al.* **Gestion des ouvrages d'art – A l'usage des départements et autres collectivités locales – Guide méthodologique**. Service d'Études techniques des routes et autoroutes Ed. Mativox. France, 2006.

LU, P.; WANG, H.; TOLLIVER, D. (2019). Prediction of Bridge Component Ratings Using Ordinal Logistic Regression Model. **Mathematical Problems in Engineering**, 2019, 9797584, 11 p. <https://doi.org/10.1155/2019/9797584>.

MA, Z.; CHOI, J.; SOHN, H. Three-dimensional structural displacement estimation by fusing monocular camera and accelerometer using adaptive multi-rate Kalman filter. **Engineering Structures**, v. 292, p. 116535, 2023. <https://doi.org/10.1016/j.engstruct.2023.116535>.

MADANAT, S. Incorporating inspection decisions in pavement management. **Transportation Research Part B**, 1993. v. 27, n. 6, p. 425–438.

MARCHETTI, O. **Pontes em concreto armado**. [S.l.]: Blucher, 2013, V. 3, p. 267.

MARZOUK, M.; ABDELKADER, E. M.; ZAYED, T. A probabilistic-based deterioration model using Ground Penetrating Radar. *In*: ISARC 2018 - 35th International Symposium on Automation and Robotics in Construction and International AEC/FM Hackathon: The Future of Building Things, 2018. n. July.

MAŠOVIĆ, S.; HAJDIN, R. (2013). Modelling of bridge elements deterioration for Serbian bridge inventory. **Structure and Infrastructure Engineering**, 10(8), 976–987. <https://doi.org/10.1080/15732479.2013.774426>.

MAŠOVIĆ, S.; STOŠIĆ, S.; HAJDIN, R. Application of semi-Markov decision process in bridge management. [S.l.]: [s.n.], 2015. p. 1017–1024.

MATOS, J.; CASAS, J. R. COST Action TU1406 and main results on bridge lifecycle management. *In*: **INTERNATIONAL SYMPOSIUM ON LIFE-CYCLE CIVIL ENGINEERING (IALCCE)**, 6., 2018. Ghent. Belgium. Proceedings [...]. Belgium, 2018. CRC Press, p. 1-8.

MATOS, J. C.; CASAS, J. R.; FERNANDES, S. 2016. COST Action TU1406 Quality Specifications for Roadway Bridges (BridgeSpec). *In*: **INTERNATIONAL CONFERENCE ON BRIDGE MAINTENANCE, SAFETY AND MANAGEMENT (IABMAS)**, 8., 2016. Foz do Iguaçu. Proceedings [...]. Foz do Iguaçu, 2016b. 8p.

MEYER, K. F. **Passarelas e pontes para dutos**. 2. ed. Belo Horizonte: RONA. 2011. 243p

MIGLIACCIO, G.; BOGUS, S. M.; CORDOVA-ALVIDREZ, A. Continuous quality improvement techniques for data collection in asset management systems. **Journal of Construction Engineering and Management**, v. 140, 2014. [https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0000427](https://doi.org/10.1061/(ASCE)CO.1943-7862.0000427).

MINISTRY OF HOUSING AND URBAN-RURAL DEVELOPMENT. Technical code of maintenance for city bridges, CJJ99. China. 2003. Beijing: Author.

MINISTRY OF LAND, INFRASTRUCTURE AND TRANSPORT. Roadworks Manual,

- Ministry of Land, Infrastructure and Transport, Sejong, Korea. 2016.
- MINISTRY OF LAND, INFRASTRUCTURE, AND TRANSPORT. Guideline of safety inspection and in-depth safety inspection for structures. (2012c). Sejong: Author.
- MINISTRY OF LAND, INFRASTRUCTURE, TRANSPORTATION, AND TOURISM. White paper on land, infrastructure, transportation, and tourism in Japan. Tokyo. 2013.
- MM. CHANARD *et al.* **Gestion Des Ouvrages d'art - Guide Méthodologique**. Club d'echange d'experiences sur les routes departementales Gestion. France, 1990.
- MORCOUS, G.; LOUNIS, Z. Maintenance optimization of infrastructure networks using genetic algorithms. **Automation in Construction**, 2005. v. 14, n. 1, p. 129–142.
- MORCOUS, G.; LOUNIS, Z; CHO, Y. An integrated system for bridge management using probabilistic and mechanistic deterioration models: Application to bridge decks. **KSCE Journal of Civil Engineering**, 2010. v. 14, n. 4, p. 527–537.
- MORCOUS, G. *et al.* CASE-BASED REASONING SYSTEM ABSTRACT A bridge deterioration model is an integral part of any complete Bridge Management Systems (BMSs). Popular models, such as Markovian deterioration models, have some limitations that affect the reliability of predic. **Computing in Civil and Building Engineering**, 2000. p. 1363–1370.
- MOSCOSO, Y. F. M. Modelos De Degradação Para Aplicação Em Sistemas De Gerenciamento De Obras De Arte Especiais - OAEs. [S.l.]: Universidade de Brasília, 2017. **Tese**. ISBN 0428089518.
- MURATORI, G. P.; DEUS, E. P. Estudo e desenvolvimento de um sistema de gerenciamento aplicado às pontes rodoviárias. *In*: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO. Salvador. **Anais...** Salvador: ENEGEP, 2001.
- NEVES, L. C.; FRANGOPOL, D. M. Condition, safety and cost profiles for deteriorating structures with emphasis on bridges. **Reliability Engineering and System Safety**, 2005. v. 89, n. 2, p. 185–198.
- NIETOA, C. C.; SHANB, Y.; LEWISC, P. E HARTELLB, J. A. (2019) Bridge maintenance prioritization using analytic hierarchy process and fusion tables. **Automation in Construction**, 99–110.
- NIKNAM, ALI; HEIDARNEJAD, MOHAMMAD; MASJEDI, ALIREZA; BORDBAR, AMIN. Data-Based Models to Investigate Protective Piles Effects on the Scour Depth About Oblong-Shaped Bridge Pier. **Results in Engineering**, v. 23, 2024. <https://doi.org/10.1016/j.rineng.2024.102759>.
- NWANGANGA, Fred; CHAPPLE, Mike. Practical Machine Learning in R. Indianapolis: **John Wiley & Sons, Inc**, 2020. 447 p. ISBN: 978-1-119-59151-1

NOGUEIRA, B. L. N. Ponte transpondo o rio Jaguaribe. João Pessoa, 2003. **Trabalho de Diplomação** (Graduação em Arquitetura e Urbanismo) – Centro de Tecnologia/ Universidade Federal da Paraíba.

NOORTWIJK, J. M. V.; FRANGOPOL, D. M. Two probabilistic life-cycle maintenance models for deteriorating civil infrastructures. **Probabilistic Engineering Mechanics**, 2004. v. 19, n. 4, p. 345–359.

OBAMA, K.; KAITO, K.; KOBAYASHI, K. Mixed Poisson deterioration model for bridge management. **Proceedings - 2013 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2013**, 2013. p. 3989–3993.

OKASHA, N. M.; FRANGOPOL, D. M. Integration of structural health monitoring in a system performance based life-cycle bridge management framework. **Structure and Infrastructure Engineering**, 2012. v. 8, n. 11, p. 999–1016.

OLIVEIRA, C. B. L. Determinação e Análise de Taxas de Deterioração de Pontes Rodoviárias do Brasil. **Tese**. [S.l.]: Universidade Federal De Minas Gerais, 2019.

OLIVEIRA, G. C. Pontes, para que? João Pessoa, 1999. **Trabalho de Diplomação** (Graduação em Arquitetura e Urbanismo) – Centro de Tecnologia/ Universidade Federal da Paraíba.

OMAR, T.; NEHDI, M. **Tools for Concrete Bridges: a New Look**. 2016. p. 1–11.

ONOUFRIOU, T.; FRANGOPOL, D. M. Reliability-based inspection optimization of complex structures: A brief retrospective. **Computers and Structures**, 2002. v. 80, n. 12, p. 1133–1144.

ONTARIO MINISTRY OF TRANSPORTATION. **Field Inspection Guide**. Ontario, 2008.

ONTARIO MINISTRY OF TRANSPORTATION. **Ontario Structure Inspection Manual (OSIM)**. Ontario, 2008.

ORCESI, A. D.; FRANGOPOL, D. M.; KIM, S. Optimization of bridge maintenance strategies based on multiple limit states and monitoring. **Engineering Structures**, 2010. v. 32, n. 3, p. 627–640. <http://dx.doi.org/10.1016/j.engstruct.2009.11.009>.

OVERSEAS ROAD NOTE 7 - **A Guide to Bridge Inspection and Data Systems for District Engineers**. Transport and Road Research Laboratory. Vol 1. United Kingdom, 1988.

OVERSEAS ROAD NOTE 7 - **Bridge Inspector's Handbook**. TRL Limited. Vol 2. United Kingdom, 2004

OZYÜKSEL ÇİFTÇIOĞLU, A.; NASER, M. Z. (2024). Identifying and estimating causal effects of bridge failures from observational data. **Journal of Infrastructure Intelligence and Resilience**, 3(1), 100068. <https://doi.org/10.1016/j.iintel.2023.100068>.

QIAO, Y. *et al.* Acquiring insights into infrastructure repair policy using discrete choice models. **Transportation Research Part A: Policy and Practice**, 2018. v. 113, n. November 2017, p. 491–508. <https://doi.org/10.1016/j.tra.2018.04.020>.

QIN, Q.; WANG, J. X. Optimization of bridge management strategy based on time-dependent reliability and pre-posterior decision analysis. **Bridge Design, Construction and Maintenance - Proceedings of the two-day International Conference organised by the Institution of Civil Engineers, ICE**, 2007. n. 1998, p. 566–575.

R CORE TEAM. *R: A language and environment for statistical computing*. **R Foundation for Statistical Computing**, Vienna, Austria, 2024. Disponível em: <https://www.r-project.org>.

RENS, K. L.; NOGUEIRA, C. L.; NEIMAN, Y. M.; GRUBER, J. T.; JOHNSON, L. E. Bridge Management System for the City and County of Denver. **Smart Microgrids**, 1999. v. 4, n. November, p. 161–192.

RENS, BRANCO, H. **Colapsos de pontes : Lições aprendidas**. [s.l: s.n.].

RIZQIANSYAH, AKBAR; CAPRANI, COLIN C. Hierarchical Bayesian modeling of highway bridge network extreme traffic loading. **Structural Safety**, v. 111, 2024. Disponível em: <https://doi.org/10.1016/j.strusafe.2024.102503>.

ROSENBLUM, A. Pontes em estruturas segmentadas pré-moldadas protendidas: análise e contribuições ao gerenciamento do processo construtivo. **Dissertação**. 2009.

ROSTAM, S. Management & maintenance of concrete bridges an assessment of the European scene. **Construction and Building Materials**, 1989. v. 3, n. 3, p. 159–163.

ROUSE, M. Predictive modeling: definition. **Tech Target, Search Enterprise AI**, 2018. Disponível em: <https://searchenterpriseai.techtarget.com/definition/predictive-modeling>. Acesso em: 16 set. 2023.

RUCK, G.; FRANCIS, K. Bridge model validation at Indiana DOT. **Pavement and Asset Management - Proceedings of the World Conference on Pavement and Asset Management, WCPAM 2017**, 2019. p. 787–794.

SALEH, A. M.; MANSOUR, O. A.; ABBAS, O. S. Toward an Egyptian Bridge Management System. **HBRC Journal**, 2013. v. 9, n. 3, p. 227–234. <http://dx.doi.org/10.1016/j.hbrcj.2013.08.003>.

SAYDAM, D.; BOCCHINI, P.; FRANGOPOL, D. M. Time-dependent risk associated with deterioration of highway bridge networks. **Engineering Structures**, 2013. v. 54, p. 221–233. <http://dx.doi.org/10.1016/j.engstruct.2013.04.009>.

SCHELLENBERG, K.; HESS, R.; MÜLLER, R.; HUBER, H. Defining a Bridge Maintenance Strategy –Some Practical Constraints. **19th IABSE Conference**. Stockholm. 2016.

SIABIL, S. Z.; GHARAIBEH, N. G. Assessing the effect of considering multiple data properties on detecting potential errors in pavement condition data. **Transportation Research Record**, v. 2639, p. 39–45, 2017. <https://doi.org/10.3141/2639-05>.

SILVA, C. J. G.; MONTEIRO, E. C. B.; VITÓRIO, J. A. P. “Condições estruturais e funcionais de pontes e viadutos das rodovias federais de Pernambuco”, **Revista ALCONPAT**, 8 (1), pp. 79 – 93. 2018.

SILVA, CLAYTON JOSÉ GOMES. Uso do método dos fatores e da análise de sobrevivência na estimativa de vida útil da superestrutura de pontes e viadutos rodoviários. 2022. **Tese (Doutorado)** – Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, Programa de Pós-Graduação em Engenharia Civil, Recife, 2022.

SÖDERQVIST, M. K.; VEIJOLA, M. The Finnish Bridge Management System. **Structural Engineering International: Journal of the International Association for Bridge and Structural Engineering (IABSE)**, 1998. v. 8, n. 4, p. 315–319.

SRIKANTH, I.; AROCKIASAMY, M. Deterioration models for prediction of remaining useful life of timber and concrete bridges: A review. **Journal of Traffic and Transportation Engineering (English Edition)**, 2020. v. 7, n. 2, p. 152–173. <https://doi.org/10.1016/j.jtte.2019.09.005>.

STEWART, M. G.; ROSOWSKY, D. V. Time-dependent reliability of deteriorating reinforced concrete bridge decks. **Structural Safety**, 1998. v. 20, n. 1, p. 91–109.

STEWART, M. G.; ROSOWSKY, D. V.; VAL, D. V. Reliability-based bridge assessment using risk-ranking decision analysis. **Structural Safety**, 2001. v. 23, n. 4, p. 397–405.

STRAUSS, A.; MANDIĆIVANKOVIĆ, A.; MATOS, J.C. E CASAS, J.R. (2017) Performance Indicators for Road Bridges Overview of Findings and Future progress. The Value of Structural Health Monitoring for the reliable Bridge Management. **TU1406 Cost Action**. March. Zagrebe, Croácia.

SUN, Shuang; LIANG, Li; LI, Ming; LI, Xin. Multidamage Detection of Bridges Using Rough Set Theory and Naive-Bayes Classifier. **Mathematical Problems in Engineering**, v. 2018. Disponível em: <https://doi.org/10.1155/2018/5487273>.

TANG, D.; HUANG, M. The sustainable development of bridges in China: collapse cause analysis, existing management dilemmas and potential solutions. **Buildings**, v. 14, n. 2, p. 419, 2024. <https://doi.org/10.3390/buildings14020419>.

TAVARES, R. Construindo mapas conceituais. **Ciências & Cognição**. [S.l.]: [s.n.], 2007, V. 12, p. 72–85.

THOMAS, O.; SOBANJO, J. Semi-Markov models for the deterioration of bridge elements. **Journal of Infrastructure Systems**, 2016. v. 22, n. 3, p. 1–12.

THOMPSON, P. Estimating asset deterioration and life expectancy by using levels of service. **Transportation Research Record**, 2012. n. 2285, p. 19–26.

THOMPSON, P. D.; ELLIS, R. M. Advanced decision support in the Ontario bridge management system. **Structures Congress 2000: Advanced Technology in Structural Engineering**, 2004. v. 103.

THOMPSON, P.; SOBANJO, J.; KERR, R. Modeling the risk of advanced deterioration in bridge management systems. **Transportation Research Record**, 2013. n. 2360, p. 52–59.

TIMERMAN, J. Inspeção de pontes: o estágio atual da normalização. **Slides**. São Paulo. 2015.

TOLLIVER, D.; LU, P. Analysis of Bridge Deterioration Rates: A Case Study of the Northern Plains Region. **Journal of the Transportation Research Forum**, 2012. v. 50, n. 2.

TURKSEZER, Z. I.; C. IACOVINO, P. F.; GIORDANO AND M. P. LIMONGELLI. 2021. “Development and implementation of indicators to assess bridge inspection practices” **J. Constr. Eng. Manage.** 147 (12): 04021165. [https://doi.org/10.1061/\(ASCE\)CO.1943-7862.0002195](https://doi.org/10.1061/(ASCE)CO.1943-7862.0002195).

VALENZUELA, S.; SOLMINIHAC, H. DE; ECHAVEGUREN, T. Proposal of an integrated index for prioritization of bridge maintenance. **Journal of Bridge Engineering**, 2010. v. 15, n. 3, p. 337–343.

VITÓRIO, J. A. P. – **Pontes Rodoviárias – Fundamentos, Conservação e Gestão**, Livro editado pelo Conselho Regional de Engenharia, Arquitetura e Agronomia de Pernambuco, Recife, 2002.

VOLLAND, B.; FARSI, M.; LASVAUX, S.; PADEY, P. Service life of building elements: an investigation. **IRENE Working Paper**, 2020.

VU, K. A. T.; STEWART, M. G. Structural reliability of concrete bridges including improved chloride-induced corrosion models. **Structural Safety**, 2000. v. 22, n. 4, p. 313–333.

WANG, Y.; CAI, C. S.; HAN, B.; XIE, H.; BAO, F.; WU, H. (2024). A deep learning-based approach for assessment of bridge condition through fusion of multi-type inspection data. **Engineering Applications of Artificial Intelligence**, 128, 107468. <https://doi.org/10.1016/j.engappai.2023.107468>.

WEI, S.; BAO, Y.; LI, H. Optimal policy for structure maintenance: A deep reinforcement learning framework. **Structural Safety**, 2020. v. 83, n. November 2019, p. 101906. Disponível em: <<https://doi.org/10.1016/j.strusafe.2019.101906>>.

WIJESURIYA, U. A., & TENNANT, A. G. (2022). Binary logistic regression approach for decision making in bridge management. **Infrastructure Asset Management**, 9(2), 89-99. <https://doi.org/10.1680/jinam.21.00037>.

WU, D. *et al.* A life-cycle optimization model using semi-markov process for highway bridge maintenance. **Applied Mathematical Modelling**, 2017. v. 43, p. 45–60. <http://dx.doi.org/10.1016/j.apm.2016.10.038>.

WU, YING; WANG, YIGANG; LIU, HONGBING; XIE, LIPING; JIAO, LILI; LU, PENGZHEN. Risk assessment of bridge construction investigated using random forest algorithm. **Scientific Reports**, v. 14, p. 20964, 2024. DOI: 10.1038/s41598-024-72051-5. Disponível em: [https://doi.org/10.1038/s41598-024-72051-](https://doi.org/10.1038/s41598-024-72051-5)

YIANNI, P. C. *et al.* Incorporating local environmental factors into railway bridge asset management. **Engineering Structures**, 2016. v. 128, p. 362–373. <http://dx.doi.org/10.1016/j.engstruct.2016.09.038>.

ZHANG, H.; MARSH, D. W. R. Multi-state deterioration prediction for infrastructure asset: Learning from uncertain data, knowledge and similar groups. **Information Sciences**, 2020. v. 529, p. 197–213. <https://doi.org/10.1016/j.ins.2019.11.017>.

ANEXO I – PROGRAMAÇÃO EM R PARA APLICAÇÃO DOS ALGORITMOS E OBTENÇÃO DOS CENÁRIOS

#####EXPLICANDO A INSUFICIÊNCIA ESTRUTURAL#####

IMPORTAÇÃO DE BIBLIOTECAS

Instalando e carregando todas as bibliotecas necessárias

```
library(MASS)
install.packages('e1071');library(e1071)
install.packages('caret');library(caret)
install.packages('caTools');library(caTools)
install.packages('class');library(class)
install.packages('h2o'); library(h2o)
install.packages('randomForest'); library(randomForest)
install.packages('bnlearn'); library(bnlearn)
install.packages("tsutils"); library(tsutils)
install.packages('tstools'); library(tstools)
install.packages('visNetwork'); install.packages(visNetwork)
install.packages('car'); library(car)
install.packages('rms'); library(rms)
```

IMPORTAÇÃO E ORGANIZAÇÃO DO DATA FRAME

#Importando o data frame com dados das características das OAE e das patologias

dmai=read.table(file.choose(),head=T,dec=",") # Escolher o arquivo com data frame no formato "txt"

#Adicionando o data frame "dmai" ao diretório corrente

attach(dmai)

#Definindo as variáveis como fatores

```

dmai$desplac=factor(dmai$desplac)
dmai$conc.desagreg=factor(dmai$conc.desagreg)
dmai$IDADE=factor(dmai$IDADE)
dmai$IDADE2=factor(ifelse(dmai$IDADE==1 |
dmai$IDADE==2,1,dmai$IDADE))#Agrupando as categorias do tempo de inauguração das
pontes
dmai$TIPO_ESTRUTURA=factor(dmai$TIPO_ESTRUTURA)
dmai$TREM_TIPO=factor(dmai$TREM_TIPO)
dmai$INSUF_ESTRUTURAL=factor(dmai$INSUF_ESTRUTURAL)
dmai$ferr.oxid=factor(dmai$ferr.oxid)
dmai$man.umid=factor(dmai$man.umid)
dmai$TREM_TIPO=factor(dmai$TREM_TIPO)
dmai$NT_GERAL=factor(dmai$NT_GERAL)
dmai$LARGURA_PISTA=scale(dmai$LARGURA_PISTA)
dmai$COMPRIMENTO=scale(dmai$COMPRIMENTO)
dmai$LARGURA=scale(dmai$LARGURA)

```

```

#Adicionando o data frame "dmai" ao diretório corrente
attach(dmai)

```

ANÁLISE DO JULGAMENTO DE INSUFICIÊNCIA ESTRUTURAL BASEADO EM
UMA ABORDAGEM DE REGRESSÃO

```

#Definindo um modelo completo (com todas as variáveis do data frame)

```

```

m=glm(INSUF_ESTRUTURAL~COMPRIMENTO+LARGURA+desplac+jun.dan.inex.exp+in
filt+conc.desagreg+lixiv+man.umid+factor(TREM_TIPO)+N_VAOS+LARGURA_PISTA+fac
tor(TIPO_ESTRUTURA),family=binomial(link="logit"));summary(m)

```

```

#Aplicando o método stepwise backward

```

```

stepAIC(m)

```

```

# Modelos de regressão logística selecionados

m=glm(formula = INSUF_ESTRUTURAL ~ displac + conc.desagreg + factor(IDADE) +
LARGURA_PISTA + factor(TIPO_ESTRUTURA), family = binomial(link = "logit"))

# Modelos contendo apenas variáveis com parâmetros significativos

## Modelo I

mI=glm(formula = INSUF_ESTRUTURAL ~ displac + conc.desagreg + factor(IDADE2) +
factor(TIPO_ESTRUTURA), family = binomial(link = "logit"))

summary(mI)

## Modelo II

mII=glm(formula = INSUF_ESTRUTURAL ~ displac + conc.desagreg + LARGURA_PISTA
+ factor(TIPO_ESTRUTURA), family = binomial(link = "logit"))

summary(mII)

## Obtendo os valores de razão da chance para os modelos

exp(coef(mI))

exp(coef(mII))

# Obtendo os intervalos de confiança da razão da chance

exp(confint(mI))

exp(confint(mII))

-----

# ANÁLISE DO JULGAMENTO DE INSUFICIÊNCIA ESTRUTURAL BASEADO EM
UMA ABORDAGEM DE MACHINE LEARNING

# Dividindo a amostra entre data frame de treinamento e teste

#Dividindo a amostra entre grupo de treinamento e grupo de teste

library(caret)

library(caTools)

divisao = sample.split(dmai_IE$INSUF_ESTRUTURAL, SplitRatio = 0.75)

set.seed(1)

```

```
dmai_IE_treinamento = subset(dmai_IE, divisao == TRUE)
```

```
dmai_IE_teste = subset(dmai_IE, divisao == FALSE)
```

```
-----
```

```
#NAIVE BAYES
```

```
#Treinando o modelo
```

```
library(e1071)
```

```
classificador = naiveBayes(x = dmai_IE_treinamento[-7],y =  
dmai_IE_treinamento$INSUF_ESTRUTURAL)
```

```
print(classificador)
```

```
previsoes = predict(classificador, newdata = dmai_IE_teste[-7])
```

```
matriz_confusao = table(dmai_IE_teste$INSUF_ESTRUTURAL, previsoes)
```

```
print(matriz_confusao)
```

```
#Calculando medidas de acurácia baseadas na matriz de confusão
```

```
library(caret)
```

```
confusionMatrix(matriz_confusao)
```

```
-----
```

```
#RANDOM FOREST
```

```
#Com 10 árvores
```

```
classificador = randomForest(x = dmai_IE_treinamento[,-7],y =  
dmai_IE_treinamento$INSUF_ESTRUTURAL,ntree=10)
```

```
print(classificador)
```

```
previsoes = predict(classificador, newdata = dmai_IE_teste[,-7])
```

```
matriz_confusao = table(dmai_IE_teste$INSUF_ESTRUTURAL, previsoes)
```

```
print(matriz_confusao)
```

```
#Calculando medidas de acurácia baseadas na matriz de confusão
```

```
confusionMatrix(matriz_confusao)
```

```
#Com 20 árvores
```

```
classificador = randomForest(x = dmai_IE_treinamento[-7],y =  
dmai_IE_treinamento$INSUF_ESTRUTURAL,ntree=20)
```

```
print(classificador)
```

```
previsoes = predict(classificador, newdata = dmai_IE_teste[-7])
```

```
matriz_confusao = table(dmai_IE_teste$INSUF_ESTRUTURAL, previsoes)
```

```
print(matriz_confusao)
```

```
#Calculando medidas de acurácia baseadas na matriz de confusão
```

```
confusionMatrix(matriz_confusao)
```

```
-----
```

```
#KNN
```

```
dmai_IE=data.frame(desplac,conc.desagreg,IDADE,TIPO_ESTRUTURA,TREM_TIPO,LARG  
URA_PISTA,INSUF_ESTRUTURAL)
```

```
# Divisão entre treinamento e teste para k=5
```

```
library(class)
```

```
previsoes = knn(train = dmai_IE_treinamento[-7], test = dmai_IE_teste[-7],cl =  
dmai_IE_treinamento[,7], k = 5)
```

```
matriz_confusao = table(dmai_IE_teste[,7], previsoes)
```

```
print(matriz_confusao)
```

```
library(caret)
```

```
confusionMatrix(matriz_confusao)
```

```
-----
```

```
#REGRESSÃO LOGÍSTICA
```

```
classificador = glm(formula = INSUF_ESTRUTURAL ~ ., family = binomial, data =  
dmai_IE_treinamento)# "~." indica que o modelo deve conter todas as variáveis independentes  
da base.
```

```
probabilidades = predict(classificador, type = 'response', newdata = dmai_IE_teste[,-7])
```

```
previsoes = ifelse(probabilidades > 0.5, 1, 0)
```

```
matriz_confusao = table(dmai_IE_teste[,7], previsoes)
```

```
library(caret)
```

```
confusionMatrix(matriz_confusao)
```

#SVM

```
classificador = svm(formula = INSUF_ESTRUTURAL ~ ., data = dmai_IE_treinamento, type =  
'C-classification',
```

```
kernel = 'linear')
```

```
previsoes = predict(classificador, newdata = dmai_IE_teste[,-7])
```

```
matriz_confusao = table(dmai_IE_teste[,7], previsoes)
```

```
library(caret)
```

```
confusionMatrix(matriz_confusao)
```

PERCEPTRON MULTICAMADAS

```
h2o.init(nthreads = -1)#Para usar toda a CPU
```

```
classificador = h2o.deeplearning(y = 'INSUF_ESTRUTURAL',
```

```
training_frame = as.h2o(dmai_IE_treinamento),
```

```
activation = 'Rectifier',
```

```
hidden = c(100),
```

```
epochs = 1000)
```

#OBS: No parâmetro hidden definimos tanto o número de camadas ocultas como o número de neurônios em cada camada:

#hidden = c(100) - uma camada oculta com 100 neurônios

#hidden = c(100,100) - duas camadas ocultas com 100 neurônios cada

#hidden = c(100, 80) - uma camada oculta com 100 neurônios e outra com 80 neurônios

#OBS: epochs indica o número de vezes que ocorrerá o ajuste de pesos.

previsoes = h2o.predict(classificador, newdata = as.h2o(dmai_IE_teste[,-7]))

#OBS: Note que é necessário entrar com os dados no formato de entrada da função h2o usando "as.h2o(dmai_IE_teste[,-7])".

previsoes=as.vector(ifelse(previsoes[,3]>previsoes[,2],1,0))

matriz_confusao = table(dmai_IE_teste[,7], previsoes)

library(caret)

confusionMatrix(matriz_confusao)

APLICANDO O MÉTODO CROSS-VALIDATION COM 30 REPETIÇÕES PARA OS ALGORITMOS DE MACHINE LEARNING

#NAIVE BAYES

library(caret)

R30.AC.nb = c()

R30.KA.nb = c()

for (i in 1:30) {

 controle_treinamento = trainControl(method = 'cv', number = 10)

 modelo = train(INSUF_ESTRUTURAL ~ ., data = dmai_IE_treinamento, trControl = controle_treinamento, method = 'nb')

 AC.nb = modelo\$results\$Accuracy[2]

 KA.nb = modelo\$results\$Kappa[2]

 R30.AC.nb = c(R30.AC.nb, AC.nb)

 R30.KA.nb = c(R30.KA.nb, KA.nb)

}

```
#RANDOM FOREST
```

```
library(caret)
```

```
R30.AC.rf = c()
```

```
R30.KA.rf = c()
```

```
for (i in 1:30) {
```

```
  controle_treinamento = trainControl(method = 'cv', number = 10)
```

```
  modelo = train(INSUF_ESTRUTURAL ~ ., data = dmai_IE_treinamento, trControl =  
  controle_treinamento, method = 'rf', ntree=30)
```

```
  AC.rf = modelo$results$Accuracy[2]
```

```
  KA.rf = modelo$results$Kappa[2]
```

```
  R30.AC.rf = c(R30.AC.rf, AC.rf)
```

```
  R30.KA.rf = c(R30.KA.rf, KA.rf)
```

```
}
```

```
#KNN
```

```
R30.AC.knn = c()
```

```
R30.KA.knn = c()
```

```
for (i in 1:30) {
```

```
  controle_treinamento = trainControl(method = 'cv', number = 10)
```

```
  modelo = train(INSUF_ESTRUTURAL ~ ., data = dmai_IE_treinamento, trControl =  
  controle_treinamento, method = 'knn', tuneGrid = expand.grid(k = 5))
```

```
  AC.knn = modelo$results$Accuracy
```

```
  KA.knn = modelo$results$Kappa
```

```
  R30.AC.knn = c(R30.AC.knn, AC.knn)
```

```
  R30.KA.knn = c(R30.KA.knn, KA.knn)
```

```
}
```

```
#REGRESSÃO LOGÍSTICA
```

```
library(caret)
```

```
R30.AC.glm = c()
```

```
R30.KA.glm = c()
```

```

for (i in 1:30) {
  controle_treinamento = trainControl(method = 'cv', number = 10)
  modelo = train(INSUF_ESTRUTURAL ~ ., data = dmai_IE_treinamento, trControl =
controle_treinamento, method = 'glm', family='binomial')
  AC.glm = modelo$results$Accuracy
  KA.glm = modelo$results$Kappa
  R30.AC.glm = c(R30.AC.glm, AC.glm)
  R30.KA.glm = c(R30.KA.glm, KA.glm)
}

```

#SVM Radial

```

R30.AC.svmRadial = c()
R30.KA.svmRadial = c()
for (i in 1:30) {
  controle_treinamento = trainControl(method = 'cv', number = 10)
  modelo = train(INSUF_ESTRUTURAL ~ ., data = dmai_IE_treinamento, trControl =
controle_treinamento, method = 'svmRadial')
  AC.svmRadial = max(modelo$results$Accuracy)
  KA.svmRadial = max(modelo$results$Kappa)
  R30.AC.svmRadial = c(R30.AC.svmRadial, AC.svmRadial)
  R30.KA.svmRadial = c(R30.KA.svmRadial, KA.svmRadial)
}

```

#REDES NEURAIIS MLP

```

R30.AC.avNNet = c()
R30.KA.avNNet = c()
for (i in 1:30) {
  controle_treinamento = trainControl(method = 'cv', number = 10)
  modelo = train(INSUF_ESTRUTURAL ~ ., data = dmai_IE_treinamento, trControl =
controle_treinamento, method = 'avNNet')
  AC.avNNet = max(modelo$results$Accuracy)
  KA.avNNet = max(modelo$results$Kappa)
}

```

```

R30.AC.avNNet = c(R30.AC.avNNet, AC.avNNet)
R30.KA.avNNet = c(R30.KA.avNNet, KA.avNNet)
}

#TABELA COM AS 30 ACURÁCIAS DE CADA ALGORITMO
Repetições=1:30
ACURÁCIAS=data.frame(Repetições,R30.AC.nb,R30.AC.rf,R30.AC.knn,R30.AC.glm,R30.A
C.svmRadial,R30.AC.avNNet)
write.table(ACURÁCIAS,dec="," ,file="ACURÁCIAS.txt")

#TABELA COM OS 30 KAPPA DE CADA ALGORITMO
Repetições=1:30
KAPPA=data.frame(Repetições,R30.KA.nb,R30.KA.rf,R30.KA.knn,R30.KA.glm,R30.KA.svm
Radial,R30.KA.avNNet)
write.table(KAPPA,dec="," ,file="KAPPA.txt")

#EFETUANDO O TESTE COMPARATIVO ENTRE OS RESULTADOS DO ALGORITMO
matriz=as.matrix(dteste)
tstools::nemenyi(matriz,conf.int=0.95,plottype='vline')

-----

# INVESTIGAÇÃO DE TENDÊNCIAS NOS JULGAMENTOS SOBRE INSUFICIÊNCIA
ESTRUTURAL A PARTIR DE REDES BAYESIANAS
# Categorizando a única variável quantitativa selecionada pelo método stepwise com regressão
logística
dmai$LARGURA_PISTA=cut(dmai$LARGURA_PISTA,3)
-----

#Indicando as restrições para estimação do grafo da rede bayesiana (a black list e a white list):

##BLACK LIST ()
from.b=c("INSUF_ESTRUTURAL","INSUF_ESTRUTURAL","INSUF_ESTRUTURAL","IN
SUF_ESTRUTURAL","INSUF_ESTRUTURAL","LARGURA_PISTA","LARGURA_PISTA"

```

```
, "desplac", "desplac", "desplac", "conc.desagreg", "conc.desagreg", "conc.desagreg", "TIPO_ESTRUTURA", "TIPO_ESTRUTURA", "IDADE", "IDADE")
```

```
to.b=c("LARGURA_PISTA", "desplac", "TIPO_ESTRUTURA", "IDADE", "conc.desagreg", "TIPO_ESTRUTURA", "IDADE", "LARGURA_PISTA", "TIPO_ESTRUTURA", "IDADE", "LARGURA_PISTA", "TIPO_ESTRUTURA", "IDADE", "LARGURA_PISTA", "IDADE", "LARGURA_PISTA", "TIPO_ESTRUTURA")
```

```
restr.black=data.frame(from.b,to.b)
```

```
##WHITE LIST
```

```
from.w=c("LARGURA_PISTA", "desplac", "TIPO_ESTRUTURA", "IDADE", "conc.desagreg")
```

```
to.w=c("INSUF_ESTRUTURAL", "INSUF_ESTRUTURAL", "INSUF_ESTRUTURAL", "INSUF_ESTRUTURAL", "INSUF_ESTRUTURAL")
```

```
restr.white=data.frame(from.w,to.w)
```

```
-----
```

```
# Obtendo o grafo que otimiza a parcimônia expressa pela medida AIC
```

```
dmai_IE=data.frame(IDADE, TIPO_ESTRUTURA, LARGURA_PISTA, displac, conc.desagreg, INSUF_ESTRUTURAL)
```

```
#Definindo os nós através de um grafo sem arcos
```

```
dag=empty.graph(nodes=c("IDADE", "TIPO_ESTRUTURA", "LARGURA_PISTA", "desplac", "conc.desagreg", "INSUF_ESTRUTURAL"))
```

```
#Obtendo grafos com os nós dados que minimizem medidas de parcimônia usando o algoritmo Hill-Climbing
```

```
IE.hc.aic=hc(dmai_IE, start=dag, whitelist=restr.white, blacklist=restr.black, score="aic")
```

```
-----
```

```
#Treinando a rede bayesiana discreta
```

```
bn.mle_IE.hc.aic=bn.fit(IE.hc.aic, data = dmai_IE, method = "mle")
```

```
-----
```

```
#Aplicando testes de independência condicional para os pares de nós
```

```
## Teste  $\chi^2$ 
```

```

ci.test("TIPO_ESTRUTURA", "desplac",test = "x2", data = dmai_IE)
ci.test("TIPO_ESTRUTURA", "conc.desagreg",test = "x2", data = dmai_IE)
ci.test("TIPO_ESTRUTURA", "INSUF_ESTRUTURAL",test = "x2", data = dmai_IE)
ci.test("IDADE", "desplac",test = "x2", data = dmai_IE)
ci.test("IDADE", "conc.desagreg",test = "x2", data = dmai_IE)
ci.test("IDADE", "INSUF_ESTRUTURAL",test = "x2", data = dmai_IE)
ci.test("LARGURA_PISTA", "desplac",test = "x2", data = dmai_IE)
ci.test("LARGURA_PISTA", "desagreg",test = "x2", data = dmai_IE)
ci.test("LARGURA_PISTA", "INSUF_ESTRUTURAL",test = "x2", data = dmai_IE)
ci.test("desplac", "INSUF_ESTRUTURAL",test = "x2", data = dmai_IE)
ci.test("conc.desagreg", "desplac",test = "x2", data = dmai_IE)
ci.test("conc.desagreg", "INSUF_ESTRUTURAL",test = "x2", data = dmai_IE)

```

Teste Mutual information

```

ci.test("TIPO_ESTRUTURA", "desplac",test = "mi", data = dmai_IE)
ci.test("TIPO_ESTRUTURA", "conc.desagreg",test = "mi", data = dmai_IE)
ci.test("TIPO_ESTRUTURA", "INSUF_ESTRUTURAL",test = "mi", data = dmai_IE)
ci.test("IDADE", "desplac",test = "mi", data = dmai_IE)
ci.test("IDADE", "conc.desagreg",test = "mi", data = dmai_IE)
ci.test("IDADE", "INSUF_ESTRUTURAL",test = "mi", data = dmai_IE)
ci.test("LARGURA_PISTA", "desplac",test = "mi", data = dmai_IE)
ci.test("LARGURA_PISTA", "conc.desagreg",test = "mi", data = dmai_IE)
ci.test("LARGURA_PISTA", "INSUF_ESTRUTURAL",test = "mi", data = dmai_IE)
ci.test("desplac", "INSUF_ESTRUTURAL",test = "mi", data = dmai_IE)
ci.test("conc.desagreg", "desplac",test = "mi", data = dmai_IE)
ci.test("conc.desagreg", "INSUF_ESTRUTURAL",test = "mi", data = dmai_IE)

```

Construindo o gráfico do grafo da rede bayesiana

Definindo a estrutura do grafo

```

## Especificação dos nós da rede

structure <- empty.graph(c("IDADE", "TIPO_ESTRUTURA", "LARGURA_PISTA",
"desplac", "conc.desagreg", "INSUF_ESTRUTURAL"))

## Especificação das relações descritas no grafo

modelstring(structure) <-
"[IDADE][TIPO_ESTRUTURA][LARGURA_PISTA][conc.desagreg|IDADE:TIPO_ESTRUT
URA][desplac|IDADE:LARGURA_PISTA:conc.desagreg][INSUF_ESTRUTURAL|IDADE:TI
PO_ESTRUTURA:LARGURA_PISTA:desplac:conc.desagreg]"

# Função para plotar a rede

plot.network <- function(structure, ht = "800px") {

  nodes.uniq <- unique(c(structure$arcs[,1], structure$arcs[,2]))

  nodes <- data.frame(id = nodes.uniq,
                      label = nodes.uniq,
                      color = ifelse(nodes.uniq == "INSUF_ESTRUTURAL", "red", "darkturquoise"),
                      shadow = TRUE,
                      font = list(size = 20))

  edges <- data.frame(from = structure$arcs[,1],
                      to = structure$arcs[,2],
                      arrows = "to",
                      smooth = FALSE,
                      shadow = TRUE,
                      color = "black",
                      length = 300, # Reduzindo o comprimento para aumentar visualmente os arcos
                      width = 3) # Triplicando a espessura dos arcos

  vis <- visNetwork(nodes, edges, height = ht, width = "100%")

  # Configurando o layout hierárquico com aumento da distância horizontal entre os nós
  vis <- vis %>% visHierarchicalLayout(direction = "UD",
                                      sortMethod = "directed",
                                      nodeSpacing = 600) # Triplicando o espaçamento horizontal

```

```

# Desabilitando física para manter o layout hierárquico estático
vis <- vis %>% visPhysics(enabled = FALSE)
vis <- vis %>% visOptions(manipulation = TRUE)

return(vis)
}

# Gerando o gráfico com o layout ajustado
plot.network(structure)

-----

#####

# FORMULAÇÃO DOS CENÁRIOS
matriz_cenarios = matrix(rep(0,4*20),c(20,4))
colnames(matriz_cenarios) = c("desplac", "conc.desagreg", "IDADE2",
"TIPO_ESTRUTURA")
dcen = as.data.frame(matriz_cenarios)

#Pistas estreitas e largas)
larga = rnorm(20,mean=0,sd=0.8)
dcen$LARGURA_PISTA = sample(larga)

#Pistas de concreto
concreto = rep(1,10)
outras = rep(2,10)
dcen$TIPO_ESTRUTURA = sample(c(concreto, outras))

#OAE's mais novas e mais antigas
novas = rep(4,6)
intermediarias = rep(3,6)
antigas = rep(1,8)
dcen$IDADE2 = sample(c(novas, intermediarias,antigas))

```

```

#Com e sem patologias principais
dcen$conc.desagreg = c(rep(1,5),rep(0,5),rep(1,5),rep(0,5))
dcen$desplac = c(rep(1,5),rep(0,5),rep(0,5),rep(1,5))

#Definindo as variáveis como fatores
dcen$desplac=factor(dcen$desplac)
dcen$conc.desagreg=factor(dcen$conc.desagreg)
dcen$IDADE2=factor(dcen$IDADE2)
dcen$TIPO_ESTRUTURA=factor(dcen$TIPO_ESTRUTURA)

#####

# AJUSTANDO O MODELO DE REGRESSÃO LOGÍSTICA BINÁRIA
classificador=glm(formula = INSUF_ESTRUTURAL ~ displac + conc.desagreg +
factor(IDADE2) + factor(TIPO_ESTRUTURA), family = binomial(link = "logit"),data=dmai)

# EFETUANDO A PREVISÃO PARA OS CENÁRIOS
previsoes = predict(classificador, type="response",newdata = dcen)
classificacao = ifelse(previsoes >= 0.5514,1,0)

dcen = data.frame(dcen,previsoes,classificacao)

write.table(dcen, file="Cenários_SVM.txt",dec=",")

#####

# TREINANDO OS ALGORITMOS DE MACHINE LEARNING
dmai_IE=data.frame(desplac,conc.desagreg,IDADE2,TIPO_ESTRUTURA,INSUF_ESTRUTU
RAL)

## SUPPORT VECTOR MACHINE
classificador = svm(formula = INSUF_ESTRUTURAL ~ ., data = dmai_IE, type = 'C-
classification',

kernel = 'linear')

```

```
previsoes = predict(classificador, newdata = dcen)
```

```
dcen = data.frame(dcen,previsoes)
```

```
write.table(dcen, file="Cenários_SVM.txt",dec=",")
```

```
## PERCEPTRON MULTICAMADAS
```

```
library(h2o)
```

```
h2o.init(nthreads = -1)#Para usar toda a CPU
```

```
classificador = h2o.deeplearning(y = 'INSUF_ESTRUTURAL',
```

```
                                training_frame = as.h2o(dmai_IE),
```

```
                                activation = 'Rectifier',
```

```
                                hidden = c(10),
```

```
                                epochs = 1000)
```

```
previsoes.mlp = h2o.predict(classificador, newdata = as.h2o(dmai_IE))
```

Tentei ajustar um modelo de redes neurais artificiais do tipo perceptron multicamadas usando a função:

```
h2o.predict(classificador, newdata = as.h2o(dmai_IE))
```

Porém, o seguinte erro foi apresentado:

```
# EFETUANDO A PREVISÃO PARA OS CENÁRIOS
```

```
-----
```

```
# FORMULAÇÃO DOS 20 CENÁRIOS
```

```
matriz_cenarios = matrix(rep(0,4*20),c(20,4))
```

```
colnames(matriz_cenarios) = c("desplac", "conc.desagreg", "IDADE2",  
"TIPO_ESTRUTURA")
```

```
dcen = as.data.frame(matriz_cenarios)
```

```

#Pistas estreitas e largas)
larga = rnorm(20,mean=0,sd=0.8)
dcen$LARGURA_PISTA = sample(larga)

#Pistas de concreto
concreto = rep(1,10)
outras = rep(2,10)
dcen$TIPO_ESTRUTURA = sample(c(concreto, outras))

#OAE's mais novas e mais antigas
novas = rep(4,6)
intermediarias = rep(3,6)
antigas = rep(1,8)
dcen$IDADE2 = sample(c(novas, intermediarias,antigas))

#Com e sem patologias principais
dcen$conc.desagreg = c(rep(1,5),rep(0,5),rep(1,5),rep(0,5))
dcen$desplac = c(rep(1,5),rep(0,5),rep(0,5),rep(1,5))

#Definindo as variáveis como fatores
dcen$desplac=factor(dcen$desplac)
dcen$conc.desagreg=factor(dcen$conc.desagreg)
dcen$IDADE2=factor(dcen$IDADE2)
dcen$TIPO_ESTRUTURA=factor(dcen$TIPO_ESTRUTURA)

-----

# AJUSTANDO O MODELO DE REGRESSÃO LOGÍSTICA BINÁRIA
classificador=glm(formula = INSUF_ESTRUTURAL ~ displac + conc.desagreg +
factor(IDADE2) + factor(TIPO_ESTRUTURA), family = binomial(link = "logit"),data=dmai)

# EFETUANDO A PREVISÃO PARA OS CENÁRIOS
previsoes = predict(classificador, type="response",newdata = dcen)

```

```

classificacao = ifelse(previsoes >= 0.5514,1,0)

dcen = data.frame(dcen,previsoes,classificacao)

write.table(dcen, file="Cenários_SVM.txt",dec=",")

-----

# TREINANDO OS ALGORITMOS DE MACHINE LEARNING

dmai_IE=data.frame(desplac,conc.desagreg,IDADE2,TIPO_ESTRUTURA,INSUF_ESTRUTU
RAL)

## SUPPORT VECTOR MACHINE

classificador = svm(formula = INSUF_ESTRUTURAL ~ ., data = dmai_IE, type = 'C-
classification',

                    kernel = 'linear')

previsoes = predict(classificador, newdata = dcen)

dcen = data.frame(dcen,previsoes)

write.table(dcen, file="Cenários_SVM.txt",dec=",")

-----

# ESTIMANDO O GRAFO DA REDE BAYESIANA

dmai_IE=data.frame(desplac,conc.desagreg,IDADE,TIPO_ESTRUTURA,LARGURA_PISTA,
INSUF_ESTRUTURAL)

#WHITE LIST 2

from.w=c("LARGURA_PISTA","desplac","TIPO_ESTRUTURA","IDADE","conc.desagreg","
IDADE","IDADE")

to.w=c("INSUF_ESTRUTURAL","INSUF_ESTRUTURAL","INSUF_ESTRUTURAL","INS
UF_ESTRUTURAL","INSUF_ESTRUTURAL","desplac","conc.desagreg")

restr.white=data.frame(from.w,to.w)

```

```
#BLACK LIST
```

```
from.b=c("INSUF_ESTRUTURAL","INSUF_ESTRUTURAL","INSUF_ESTRUTURAL","INSUF_ESTRUTURAL","INSUF_ESTRUTURAL","LARGURA_PISTA","LARGURA_PISTA","desplac","desplac","desplac","conc.desagreg","conc.desagreg","conc.desagreg","TIPO_ESTRUTURA","TIPO_ESTRUTURA","IDADE","IDADE")
```

```
to.b=c("LARGURA_PISTA","desplac","TIPO_ESTRUTURA","IDADE","conc.desagreg","TIPO_ESTRUTURA","IDADE","LARGURA_PISTA","TIPO_ESTRUTURA","IDADE","LARGURA_PISTA","TIPO_ESTRUTURA","IDADE","LARGURA_PISTA","IDADE","LARGURA_PISTA","TIPO_ESTRUTURA")
```

```
restr.black=data.frame(from.b,to.b)
```

```
#DEFININDO OS NÓS ATRAVÉS DE UM GRAFO SEM ARCOS:
```

```
dag=empty.graph(nodes=c("IDADE","TIPO_ESTRUTURA","LARGURA_PISTA","desplac","conc.desagreg","INSUF_ESTRUTURAL"))
```

```
#ESTIMANDO O GRAFO DAS RELAÇÕES
```

```
IE.hc.aic=hc(dmai_IE,start=dag,whitelist=restr.white,blacklist=restr.black,score="aic")
```

```
bn.mle_IE.hc.aic=bn.fit(IE.hc.aic, data = dmai_IE, method = "mle")
```

```
# ESTIMANDO AS PROBABILIDADES CONDICIONADAS
```

```
# EFETUANDO A PREVISÃO PARA OS CENÁRIOS
```

```
library(gRain)
```

```
previsoes = classificacao = c()
```

```
junction<- compile(as.grain(bn.mle_IE.hc.aic))#Transformando a rede em uma árvore de junção para acelerar os cálculos
```

```
for(i in 1:20){
```

```
  jsex<- setEvidence(junction, nodes =  
c("desplac","conc.desagreg","IDADE2","TIPO_ESTRUTURA"), states =  
c(dcen$desplac[i],dcen$conc.desagreg[i],dcen$IDADE2[i],dcen$TIPO_ESTRUTURA[i]))#Definindo a evidência
```

```
  previsoes[i] = querygrain(jsex, nodes =  
"INSUF_ESTRUTURAL")$INSUF_ESTRUTURAL[2]#Verificando as probabilidades associadas ao nó de insuficiência estrutural
```

```
  classificacao[i] = ifelse(previsoes[i]>0.5,1,0)
```

```
}
```

```

dcen = data.frame(dcen,previsoes,classificacao)
write.table(dcen, file="Cenários_RBN.txt",dec=",")

-----

#####EXPLICANDO A NOTA ATRIBUÍDA#####

# Definindo o modelo completo (com todas as variáveis do problema)
m=lm(NT_GERAL~COMPRIMENTO+LARGURA+desplac+ferr.oxid+jun.dan.inex.exp+infil
t+conc.desagreg+lixiv+man.umid+TIPO_ESTRUTURA+TREM_TIPO+LARGURA_PISTA+I
DADE2);m

# Aplicando o método stepwise backward
fastbw(m, rule=c("aic"))

# Modelo resultante da aplicação do método stepwise backward
m=lm(NT_GERAL~LARGURA_PISTA+desplac+ferr.oxid+conc.desagreg+TIPO_ESTRUTU
RA+IDADE2);m

# Modelo I com todos os parâmetros significativos
m=lm(NT_GERAL~desplac+ferr.oxid+conc.desagreg+TIPO_ESTRUTURA+IDADE2);m
## Calculando a razão da chance (odds ratio) do modelo I
exp(coef(m))
## Calculando o intervalo de confiança da razão da chance do modelo I
exp(confint(m))

# Modelo II com todos os parâmetros significativos
m=lm(NT_GERAL~LARGURA_PISTA+desplac+ferr.oxid+conc.desagreg+TIPO_ESTRUTU
RA);m
## Calculando a razão da chance (odds ratio) do modelo I
exp(coef(m))
## Calculando o intervalo de confiança da razão da chance do modelo I

```

```
exp(confint(m))
```

```
# Calculando a acurácia para as classes da Nota atribuída
```

```
##Obtendo os valores preditos de probabilidade pelo modelo
```

```
p1=predict(m,type="fitted.ind") [,1]
```

```
p2=predict(m,type="fitted.ind") [,2]
```

```
p3=predict(m,type="fitted.ind") [,3]
```

```
p4=predict(m,type="fitted.ind") [,4]
```

```
# Convertendo as notas atribuídas em indicações sobre a ocorrência ou não de cada nota
```

```
v1=ifelse(NT_GERAL==1,1,0)
```

```
v2=ifelse(NT_GERAL==2,1,0)
```

```
v3=ifelse(NT_GERAL==3,1,0)
```

```
v4=ifelse(NT_GERAL==4,1,0)
```

```
# Calculando a AUC e acurácia para nota 1
```

```
predm1 = prediction(p1,v1)
```

```
perfp1 = performance(predm1,"tpr","fpr")@y.values[[1]]
```

```
auc1=performance(predm1,"auc")@y.values[[1]] # AUC
```

```
acc1=performance(predm1,"acc")@y.values[[1]] # Acurácia
```

```
# Calculando a AUC e acurácia para nota 1
```

```
predm2 = prediction(p2,v2)
```

```
perfp2 = performance(predm2,"tpr","fpr")
```

```
auc2=performance(predm2,"auc")@y.values[[1]] # AUC
```

```
acc2=performance(predm2,"acc")@y.values[[1]] # Acurácia
```

```
# Calculando a AUC e acurácia para nota 1
```

```
predm3 = prediction(p3,v3)
```

```
perfp3 = performance(predm3,"tpr","fpr")
```

```
auc3=performance(predm3,"auc")@y.values[[1]] # AUC
```

```
acc3=performance(predm3,"acc",cutoff=c(0,1,length(100)))@y.values[[1]] # Acurácia
```

```

# Calculando a AUC e acurácia para nota 1
predm4 = prediction(p4,v4)
perfpm4= performance(predm4,"tpr","fpr")
auc4=performance(predm4,"auc")@y.values[[1]] # AUC
acc4=performance(predm4,"acc")@y.values[[1]] # Acurácia

-----

# INVESTIGAÇÃO DA NOTA ATRIBUÍDA PARA 20 CENÁRIOS
m=lm(NT_GERAL~LARGURA_PISTA+desplac+ferr.oxid+conc.desagreg+TIPO_ESTRUTURA);m

# FORMULAÇÃO DOS 20 CENÁRIOS
matriz_cenarios = matrix(rep(0,5*20),c(20,5))
colnames(matriz_cenarios) =
c("LARGURA_PISTA","desplac","ferr.oxid","conc.desagreg","TIPO_ESTRUTURA")

dcen = as.data.frame(matriz_cenarios)

#Pistas estreitas e largas)
larga = rnorm(20,mean=0,sd=0.8)
dcen$LARGURA_PISTA = sample(larga)

#Pistas de concreto
concreto = rep(1,10)
outras = rep(2,10)
dcen$TIPO_ESTRUTURA = sample(c(concreto, outras))

#Com e sem patologias principais
dcen$conc.desagreg = c(rep(1,5),rep(0,5),rep(1,5),rep(0,5))
dcen$desplac = c(rep(1,5),rep(0,5),rep(0,5),rep(1,5))
dcen$ferr.oxid = c(rep(1,3),rep(0,3),rep(1,3),rep(0,3),rep(1,3),rep(0,5))

```

```
#Definindo as variáveis como fatores
dcen$desplac=factor(dcen$desplac)
dcen$conc.desagreg=factor(dcen$conc.desagreg)
dcen$ferr.oxid=factor(dcen$ferr.oxid)
dcen$TIPO_ESTRUTURA=factor(dcen$TIPO_ESTRUTURA)
```

```
probabilidades = predict(m,type="fitted.ind",newdata=dcen)
probabilidades = as.data.frame(probabilidades)
```

```
dcen=data.frame(dcen,probabilidades)
```

```
write.table(dcen,file="Cenários_RLO.txt",dec=",")
```

```
# INVESTIGAÇÃO DA NOTA ATRIBUÍDA USANDO REDES BAYESIANAS
```

```
# Definindo a base de dados com os nós selecionados pelo método stepwise com a regressão
```

```
dmai_NG=data.frame(IDADE,TIPO_ESTRUTURA,LARGURA_PISTA,desplac,conc.desagreg
,ferr.oxid,NT_GERAL)
```

```
##Indicando as restrições (BLACK LIST E A WHITE LIST)
```

```
#BLACK LIST
```

```
from.b=c("NT_GERAL","NT_GERAL","NT_GERAL","NT_GERAL","NT_GERAL","NT_G
ERAL","LARGURA_PISTA","LARGURA_PISTA","desplac","desplac","desplac","conc.desag
reg","conc.desagreg","conc.desagreg","TIPO_ESTRUTURA","TIPO_ESTRUTURA","IDADE
","IDADE","ferr.oxid","ferr.oxid","ferr.oxid")
```

```
to.b=c("LARGURA_PISTA","desplac","TIPO_ESTRUTURA","IDADE","ferr.oxid","conc.des
agreg","TIPO_ESTRUTURA","IDADE","LARGURA_PISTA","TIPO_ESTRUTURA","IDAD
E","LARGURA_PISTA","TIPO_ESTRUTURA","IDADE","LARGURA_PISTA","IDADE","
LARGURA_PISTA","TIPO_ESTRUTURA","LARGURA_PISTA","TIPO_ESTRUTURA","I
DADE")
```

```
restr.black=data.frame(from.b,to.b)
```

```
#WHITE LIST
```

```
from.w=c("LARGURA_PISTA","desplac","TIPO_ESTRUTURA","IDADE","conc.desagreg","ferr.oxid")
```

```
to.w=c("NT_GERAL","NT_GERAL","NT_GERAL","NT_GERAL","NT_GERAL","NT_GERAL")
```

```
restr.white=data.frame(from.w,to.w)
```

```
-----  
# Obtendo o grafo da rede que otimiza a parcimônia expressa pelo AIC
```

```
#definindo os nós através de um grafo sem arcos
```

```
dag=empty.graph(nodes=c("IDADE","TIPO_ESTRUTURA","LARGURA_PISTA","ferr.oxid","desplac","conc.desagreg","NT_GERAL"))
```

```
#Obtendo grafos com os nós dados que minimizem medidas de parcimônia usando o algoritmo Hill-Climbing
```

```
NG.hc.aic=hc(dmai_NG,start=dag,whitelist=restr.white,blacklist=restr.black,score="aic")
```

```
-----  
##Treinando a rede bayesiana discreta
```

```
bn.mle_NG.hc.aic=bn.fit(NG.hc.aic, data = dmai_NG, method = "mle")
```

```
-----  
# Aplicando os testes de independência condicionais
```

```
# Teste qui-quadrado de Pearson
```

```
ci.test("IDADE", "desplac",test = "x2", data = dmai_NG)
```

```
ci.test("IDADE", "conc.desagreg",test = "x2", data = dmai_NG)
```

```
ci.test("IDADE", "NT_GERAL",test = "x2", data = dmai_NG)
```

```
ci.test("LARGURA_PISTA", "desplac",test = "x2", data = dmai_NG)
```

```
ci.test("LARGURA_PISTA", "NT_GERAL",test = "x2", data = dmai_NG)
```

```
ci.test("TIPO_ESTRUTURA", "ferr.oxid",test = "x2", data = dmai_NG)
```

```
ci.test("TIPO_ESTRUTURA", "NT_GERAL",test = "x2", data = dmai_NG)
```

```
ci.test("desplac", "ferr.oxid",test = "x2", data = dmai_NG)
```

```
ci.test("desplac", "conc.desagreg",test = "x2", data = dmai_NG)
```

```
ci.test("desplac", "NT_GERAL",test = "x2", data = dmai_NG)
```

```
ci.test("ferr.oxid", "conc.desagreg",test = "x2", data = dmai_NG)
```

```
ci.test("conc.desagreg", "NT_GERAL",test = "x2", data = dmai_NG)
```

```
# Teste Mutual Information
```

```
ci.test("IDADE", "desplac",test = "mi", data = dmai_NG)
```

```
ci.test("IDADE", "conc.desagreg",test = "mi", data = dmai_NG)
```

```
ci.test("IDADE", "NT_GERAL",test = "mi", data = dmai_NG)
```

```
ci.test("LARGURA_PISTA", "desplac",test = "mi", data = dmai_NG)
```

```
ci.test("LARGURA_PISTA", "NT_GERAL",test = "mi", data = dmai_NG)
```

```
ci.test("TIPO_ESTRUTURA", "ferr.oxid",test = "mi", data = dmai_NG)
```

```
ci.test("TIPO_ESTRUTURA", "NT_GERAL",test = "mi", data = dmai_NG)
```

```
ci.test("desplac", "ferr.oxid",test = "mi", data = dmai_NG)
```

```
ci.test("desplac", "conc.desagreg",test = "mi", data = dmai_NG)
```

```
ci.test("desplac", "NT_GERAL",test = "mi", data = dmai_NG)
```

```
ci.test("ferr.oxid", "conc.desagreg",test = "mi", data = dmai_NG)
```

```
ci.test("conc.desagreg", "NT_GERAL",test = "mi", data = dmai_NG)
```

```
# Construindo o gráfico do grafo da rede bayesiana
```

```
structure <-
```

```
empty.graph(c("IDADE","TIPO_ESTRUTURA","LARGURA_PISTA","ferr.oxid","desplac","c  
onc.desagreg","NT_GERAL"))
```

```
modelstring(structure) <-
```

```
"[IDADE][TIPO_ESTRUTURA][LARGURA_PISTA][desplac|IDADE:LARGURA_PISTA][f  
err.oxid|TIPO_ESTRUTURA:desplac][conc.desagreg|IDADE:ferr.oxid:desplac][NT_GERAL|I  
DADE:TIPO_ESTRUTURA:LARGURA_PISTA:ferr.oxid:desplac:conc.desagreg]"
```

```
plot.network <- function(structure, ht = "800px") {
```

```
  nodes.uniq <- unique(c(structure$arcs[,1], structure$arcs[,2]))
```

```
  nodes <- data.frame(id = nodes.uniq,
```

```
    label = nodes.uniq,
```

```
    color = ifelse(nodes.uniq == "NT_GERAL", "red", "darkturquoise"),
```

```
    shadow = TRUE,
```

```
    font = list(size = 20))
```

```

edges <- data.frame(from = structure$arcs[,1],
                    to = structure$arcs[,2],
                    arrows = "to",
                    smooth = FALSE,
                    shadow = TRUE,
                    color = "black",
                    length = 300, # Mantendo a distância mais curta para aumentar visualmente os
arcos
                    width = 3) # Triplicando a espessura dos arcos

vis <- visNetwork(nodes, edges, height = ht, width = "100%")

# Configurando o layout hierárquico com aumento da distância horizontal entre os nós
vis <- vis %>% visHierarchicalLayout(direction = "UD",
                                     sortMethod = "directed",
                                     nodeSpacing = 600) # Triplicando o espaçamento horizontal

# Desabilitando física para manter o layout hierárquico estático
vis <- vis %>% visPhysics(enabled = FALSE)
vis <- vis %>% visOptions(manipulation = TRUE)

return(vis)
}

plot.network(structure)

-----

# Investigando as notas atribuídas esperadas com as redes bayesianas
# FORMULAÇÃO DOS CENÁRIOS
matriz_cenarios = matrix(rep(0,5*20),c(20,5))

```

```
colnames(matriz_cenarios) = c("desplac", "conc.desagreg", "LARGURA_PISTA", "IDADE",
"TIPO_ESTRUTURA")

dcen = as.data.frame(matriz_cenarios)
```

```
#Pistas estreitas e largas)
```

```
dcen$LARGURA_PISTA = c(rep(1,4),rep(0,4),rep(1,4),rep(0,4),rep(1,4))
```

```
#Pistas de concreto
```

```
dcen$TIPO_ESTRUTURA = sample(c(rep(1,10),rep(2,10)))
```

```
#OAE's mais novas e mais antigas
```

```
dcen$IDADE = sample(c(rep(4,6), rep(3,6),rep(1,8)))
```

```
#Com e sem patologias principais
```

```
dcen$conc.desagreg = c(rep(1,5),rep(0,5),rep(1,5),rep(0,5))
```

```
dcen$desplac = c(rep(1,5),rep(0,5),rep(0,5),rep(1,5))
```

```
#Definindo as variáveis como fatores
```

```
dcen$desplac=factor(dcen$desplac)
```

```
dcen$conc.desagreg=factor(dcen$conc.desagreg)
```

```
dcen$IDADE=factor(dcen$IDADE)
```

```
dcen$TIPO_ESTRUTURA=factor(dcen$TIPO_ESTRUTURA)
```

```
#Pistas estreitas e largas)
```

```
dcen$LARGURA_PISTA = c(rep("(5.59,8]",6),rep("(8,10.4]",6),rep("(10.4,12.8]",8))
```

```
# EFETUANDO A PREVISÃO PARA OS CENÁRIOS
```

```
library(gRain)
```

```
DESPLAC = c("desplac",20)
```

```
CONC.DESAGREG = c("conc.desagreg",20)
```

```

LARG_PI = c("LARGURA_PISTA",20)
ID = c("IDADE",20)
T_ESTR = c("TIPO_ESTRUTURA",20)
previsao1 = previsao2 = previsao3 = previsao4 = c()
junction<- compile(as.grain(bn.mle_NG.hc.aic))#Transformando a rede em uma árvore de
junção para acelerar os cálculos
for(i in 1:20){
  jsex<- setEvidence(junction, nodes =
c(DESPLAC[i],CONC.DESAGREG[i],LARG_PI[i],ID[i],T_ESTR[i]), states =
c(dcen$desplac[i],dcen$conc.desagreg[i],dcen$LARGURA_PISTA[i],dcen$IDADE[i],dcen$TI
PO_ESTRUTURA[i]))#Definindo a evidência
  previsao1[i] = querygrain(jsex, nodes = "NT_GERAL")$NT_GERAL[1]#Verificando
as probabilidades associadas ao nó de insuficiência estrutural
  previsao2[i] = querygrain(jsex, nodes = "NT_GERAL")$NT_GERAL[2]
  previsao3[i] = querygrain(jsex, nodes = "NT_GERAL")$NT_GERAL[3]
  previsao4[i] = querygrain(jsex, nodes = "NT_GERAL")$NT_GERAL[4]
}

dprevisao=data.frame(previsao1,previsao2,previsao3,previsao4)
dcen=data.frame(dcen,dprevisao)

write.table(dcen,file="CENÁRIOS_REDES BAYESIANAS_NOTA ATRIBUÍDA.txt",dec=",")

```