



Verissa Pinto Marques Queiroz

**Avaliação do ciclo de vida de pontes de aço
considerando o dano por fadiga e corrosão**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para
obtenção do grau de Mestre pelo Programa de Pós-
Graduação em Engenharia Civil do Departamento de
Engenharia Civil e Ambiental da PUC-Rio

Orientadora: Profa. Elisa Dominguez Sotelino

Rio de Janeiro
Agosto 2020



Verissa Pinto Marques Queiroz

**Avaliação do ciclo de vida de pontes de aço
considerando o dano por fadiga e corrosão**

Dissertação de Mestrado

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Programa de Pós-Graduação em Engenharia Civil da PUC-Rio. Aprovada pela Comissão Examinadora abaixo.

Profa. Elisa Dominguez Sotelino

Orientadora

Departamento de Engenharia Civil - PUC-Rio

Prof. Raul Rosas e Silva

Departamento de Engenharia Civil - PUC-Rio

Dr. Cássio Marques Rodrigues Gaspar

Departamento de Engenharia Civil - PUC-Rio

Prof. Júlio Jerônimo Holtz Silva Filho

Escola Politécnica - UFRJ

Rio de Janeiro, 28 agosto de 2020

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, da autora e do orientador.

Verissa Pinto Marques Queiroz

Graduou-se em Engenharia Civil na Universidade Federal do Pará – UFPA em 2017. Ingressou no mestrado na Pontifícia Universidade Católica do Rio de Janeiro em março de 2018, desenvolvendo dissertação na linha de pesquisa de Análise Estrutural.

Ficha Catalográfica

Queiroz, Verissa Pinto Marques

Avaliação do ciclo de vida de pontes de aço considerando o dano por fadiga e corrosão / Verissa Pinto Marques Queiroz; orientadora: Elisa Dominguez Sotelino. – 2020.

115 f. : il. color. ; 30 cm

Dissertação (mestrado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Civil e Ambiental, 2020.

Inclui bibliografia

1. Engenharia Civil e Ambiental - Teses. 2. Pontes de aço. 3. Manutenção. 4. Redes neurais. 5. Corrosão-fadiga. 6. Confiabilidade. I. Sotelino, Elisa Dominguez. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Civil e Ambiental. III. Título.

CDD: 624

Aos meus pais, Verônica e Joaquim, pelo
apoio e confiança.

Agradecimentos

A Deus, por iluminar e abençoar os caminhos que segui até aqui.

Aos meus pais, Joaquim e Verônica, por todo amor, apoio e paciência durante não só essa jornada, mas em toda a minha vida. Vocês são meu porto seguro e minha maior inspiração. Agradeço também a minha irmã, Larissa, minha madrinha, Ana Francinete, meus tios, tias, primos e avó, pelo amor e apoio sempre presentes.

Ao meu namorado, Leonardo, pelo amor, amizade e companheirismo. Obrigada por me escutar, me acalmar e me incentivar mesmo nos meus momentos de teimosia. Obrigada por estar presente, mesmo quando há a distância física entre nós, e por me motivar a ir atrás dos meus sonhos.

A todos os meus amigos e amigas de vida, especialmente à Manoela e Royanne, pelo apoio, risadas, desabafos tão necessários nos últimos tempos e conversas tão terapêuticas. Agradeço também a minha amiga Luiza que conheci na UFPA e que compartilhou comigo não só a moradia no Rio, mas também vários momentos alegria e apreensão dessa nossa experiência. Sua companhia e amizade foram muito importantes durante essa jornada.

A todos os professores da PUC-Rio que contribuíram de alguma forma para minha formação, especialmente à minha orientadora Elisa, pelo apoio, dedicação, confiança e incentivo na realização deste trabalho.

Aos meus amigos do mestrado, em especial a William, Júlio, Guilherme, Ronald e todos da comunidade “Chora não coleguinha”, pela amizade inestimável que nos permitiu tantos momentos de alegria, apoio, confiança e até mesmo superação diante de alguns desesperos. Agradeço também aos amigos Hélder e Felipe Tourinho que sempre se mostraram dispostos e disponíveis em me ajudar em vários momentos de minha pesquisa.

Aos alunos de iniciação científica, Caio e Gabriel (especialmente), que participaram do grupo de pesquisa de RNA e cuja contribuição foi essencial para a elaboração de diversos tópicos deste trabalho.

A CAPES e a PUC-Rio. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Resumo

Queiroz, Verissa Pinto Marques; Sotelino, Elisa Dominguez (Orientadora). **Avaliação do ciclo de vida de pontes de aço considerando o dano por fadiga e corrosão**. Rio de Janeiro, 2020. 115p. Dissertação de Mestrado – Departamento de Engenharia Civil, Pontifícia Universidade Católica do Rio de Janeiro.

Pontes rodoviárias são estruturas sujeitas à ação conjunta de fadiga e corrosão. Nesse sentido, este trabalho propõe um protótipo de sistema para auxiliar na tomada de decisão sobre a manutenção de pontes de viga de aço, no qual apenas pontes simplesmente apoiadas são consideradas. O sistema considera os efeitos da corrosão-fadiga e estima o tempo de vida útil dessas estruturas a partir de uma análise de confiabilidade estrutural. Tal análise é baseada nas curvas S-N para fadiga da norma americana AASHTO e na regra do acúmulo de dano de Miner. Para considerar a perda de material e a perda de resistência causadas pela corrosão, são realizados ajustes nos parâmetros de fadiga do modelo de confiabilidade utilizado. Além disso, algumas alternativas de manutenção que reduzem a taxa de degradação são consideradas no sistema com a correção dos parâmetros de corrosão do material. O sistema utiliza uma rede neural artificial para estimar as tensões nas vigas de aço com a passagem de um veículo de fadiga da AASHTO a partir de dados geométricos e de material da ponte. A base de dados utilizada para o desenvolvimento da rede neural foi criada a partir de resultados de simulações por elementos finitos. O ciclo de vida de uma ponte de aço projetada conforme a norma americana é simulado usando o sistema proposto. Através dessa simulação, conclui-se que o tempo de vida útil da mesma está relacionado com a combinação dos parâmetros de tráfego e da agressividade do ambiente. Conclui-se também que o aumento no volume de tráfego médio diário de caminhões (ADTT) pode causar uma redução de 48% a 76% na vida útil e dependendo do aumento na sua taxa de crescimento anual a redução pode ser de até 80%. As alternativas de lavagem da superestrutura proporcionam ganho de vida útil para todos os ambientes, sobretudo no ambiente marinho (podendo chegar até 30%). No entanto, em alguns dos cenários de tráfego testados nas simulações esse ganho não é suficiente para garantir o tempo de vida útil mínimo recomendado pela AASHTO.

Palavras-chave

Pontes de aço; manutenção; redes neurais; corrosão-fadiga; confiabilidade

Abstract

Queiroz, Verissa Pinto Marques; Sotelino, Elisa Dominguez (Advisor). **Life cycle assessment of steel bridges considering fatigue and corrosion damage**. Rio de Janeiro, 2020. 115p. Dissertação de Mestrado – Departamento de Engenharia Civil, Pontifícia Universidade Católica do Rio de Janeiro.

Highway bridges are structures subjected to the both action of fatigue and corrosion. In this sense, this research proposes the prototype of a system to assist in the maintenance decision making process of steel beam bridges, in which only simply supported steel girder bridges are considered. The system contemplates the effects of corrosion-fatigue and estimates the lifetime of these structures based on a structural reliability analysis. Such analysis is based on AASHTO S-N fatigue curves and Miner's damage accumulation rule. In order to account for material and resistance loss caused by corrosion, adjustments are made to the fatigue parameters of the reliability model used. In addition, some maintenance strategies that reduce the rate of corrosion are considered in the system by correcting the corrosion parameters of the material. The system uses an artificial neural network model to estimate the stresses in steel beams under the passage of an AASHTO fatigue vehicle using geometric and material data from the bridge. The database used for the development of the neural network was created from finite element simulations results. The life cycle of a steel bridge, designed according to the AASHTO American standard, is simulated using the proposed system. Through this simulation, it is concluded that the structure's lifetime is related to the combination of traffic parameters and the environment corrosivity. It is also observed that the increase in the average daily truck traffic (ADTT) can cause a reduction from 48% to 76% in the bridge's lifetime and depending on its annual growth increase rate the reduction can go up to 80%. Maintenance alternatives for the superstructure such as washing provide a lifetime gain for all environments, especially in the marine environment (up to 30%). However, in some of the tested traffic scenarios this gain is not sufficient to guarantee the minimum service life recommended by AASHTO.

Keywords

Steel bridge; maintenance; neural network; corrosion-fatigue; reliability

Sumário

1	Introdução	21
1.1	Motivação	21
1.2	Objetivo	22
1.3	Escopo	22
1.4	Estrutura do trabalho	23
2	Referencial Teórico	25
2.1	Fadiga	25
2.1.1	Curvas S-N	26
2.1.2	Acúmulo de Dano – Palmgreen-Miner	27
2.1.3	Análise de fadiga segundo normas de projeto	27
2.2	Corrosão-fadiga	32
2.2.1	Métodos para quantificar a perda de resistência à fadiga devido à corrosão	33
2.2.2	Modelo de corrosão para pontes de aço	37
2.3	Confiabilidade estrutural	40
2.4	Redes Neurais	44
2.4.1	Unidade de processamento das redes neurais	44
2.4.2	Arquitetura e topologia	46
2.4.3	Tratamento dos dados	47
2.4.4	Algoritmo de treinamento	47
2.4.5	Critério de parada	49
2.4.6	Avaliação e métricas de desempenho do modelo	49
2.4.7	Modelos de RNA e de aprendizado de máquina na avaliação do dano em pontes de aço	51
3	Método de pesquisa	55
3.1	Modelagem de pontes em Elementos Finitos	55
3.1.1	Validação do modelo – Ponte Nebraska	56
3.2	Configurações de pontes da base de dados	61
3.2.1	Modelos em EF das pontes da base de dados	65
3.3	Elaboração do modelo de redes neurais	68
3.3.1	Aquisição e análise dos dados	68
3.3.2	Seleção dos atributos	69
3.3.3	Configuração dos experimentos	70
3.3.4	Estratégia para escolha do modelo	72
3.3.5	Critérios de parada	73
3.3.6	Definição do modelo final	74
3.3.7	Resultados	75
3.4	Avaliação da segurança estrutural de acordo com a análise do índice de confiabilidade	79

3.4.1	Confiabilidade da fadiga em pontes de aço	80
3.4.2	Corrosão	81
3.5	Sistema de manutenção de pontes de aço	84
4	Exemplo numérico	90
4.1	Estrutura considerada	90
4.1.1	Simulações	91
4.1.2	Efeito do volume de tráfego (ADTT)	92
4.1.3	Efeito da taxa de crescimento anual do volume de tráfego	93
4.1.4	Efeito das atividades de manutenção	94
5	Conclusão	98
5.1	Sugestões para trabalhos futuros	100
6	Referências Bibliográficas	102
	Apêndice I – Resultados da validação cruzada dos modelos de RNA	108
	Apêndice II – Matriz de pesos e viés do modelo de RNA	111
	Apêndice III – Simulações com uso do sistema	113

Lista de Figuras

Figura 1 – Exemplo esquemático de uma curva S-N (adaptado de Leitão, 2014)	26
Figura 2 – Faixa de tensão de um detalhe estrutural (adaptado de Grubb et al., 2015)	28
Figura 3 – Curva S-N da (AASHTO, 2012)	28
Figura 4 – Exemplos de detalhes Estruturais: (a) Solda da mesa inferior com a alma (Categoria B); (b) solda do enrijecedor transversal (Categoria C'); (AASHTO, 2012)	29
Figura 5 – Curva S-N esquemática para um detalhe típico na norma AASHTO (adaptado de Chung, 2004)	29
Figura 6 – Caminhão para análise da fadiga (adaptado de Grubb et al., 2015)	31
Figura 7 – Representação gráfica do fator de entalhe de fadiga (FNF) e fator de entalhe de corrosão (CNF) (adaptado de Hosseini et al., 2013)	35
Figura 8 – Regiões típicas de corrosão para pontes de aço (Kayser, 1988)	37
Figura 9 – Modelo de padrão de corrosão proposto por Czarnecki (2006)	37
Figura 10 - Taxas de corrosão (adaptado de Park et al., 1998)	39
Figura 11 – Definição de β usando características estatísticas da resistência e do carregamento (adaptado de Russo et al., 2016)	41
Figura 12 – Neurônio artificial (adaptado de Haykin, 2009)	45
Figura 13 – Estrutura de uma rede MLP	47
Figura 14 – Direções de propagação do sinal funcional e do erro (adaptado de Haykin, 2009)	48
Figura 15 – (a) seção transversal da ponte; (b) detalhe da seção transversal da viga (adaptado de Santos, 2015)	57
Figura 16 – Setup da prova de carga (Azizinamini et al., 1995)	58
Figura 17 – Modelo em EF da ponte da Universidade de Nebraska	60

Figura 18 – Dimensões (em mm) da barreira do tipo New Jersey (a) considerada na base de dados e (b) representada no modelo em EF	66
Figura 19 – Posicionamento longitudinal do veículo a partir da linha de influência de uma estrutura simplesmente apoiada de 20 metros	67
Figura 20 – Posicionamento transversal do veículo	67
Figura 21 – Histograma dos valores de tensão unitária máxima	69
Figura 22 – Ilustração da regra de parada antecipada baseada na técnica de validação cruzada (adaptado de Haykin, 2009)	73
Figura 23 – Representação esquemática da rede neural artificial	75
Figura 24 – Matriz de correlação das variáveis de entrada e saída	77
Figura 25 – Dispersão entre os valores de tensão máxima prevista x real	78
Figura 26 – Histograma do erro para o modelo de RNA	79
Figura 27 – Seção transversal da viga (a) sem corrosão e (b) com corrosão	83
Figura 28 – Fluxograma do sistema	87
Figura 29 – Interface gráfica do sistema - aba "Geometria/ Material"	88
Figura 30 – Interface gráfica do sistema - aba "Dados ambientais"	88
Figura 31 – Interface gráfica do sistema - aba "Dados do tráfego"	89
Figura 32 – Interface gráfica do sistema - aba "Resultados"	89
Figura 33 – Seção transversal típica de pontes de aço (adaptado de BARTH, 2015)	90
Figura 34 – Índice de confiabilidade ao longo do tempo para os ambientes: Rural, Urbano/ Industrial e Marinho (conjunto de simulação 1)	92
Figura 35 – Índice de confiabilidade ao longo do tempo para os ambientes: Rural, Urbano/ Industrial e Marinho (conjunto de simulação 2, experimento 1: $r=3\%$)	93
Figura 36 – Índice de confiabilidade ao longo do tempo para os ambientes: Rural, Urbano/ Industrial e Marinho (conjunto de simulação 2, experimento 2: $r=5\%$)	94

Figura 37 – Índice de confiabilidade ao longo do tempo no ambiente marinho com (a) ADTT=10000; $r=0\%$ e (b) ADTT=2500; $r=3\%$	95
Figura 38 – Índice de confiabilidade ao longo do tempo (ADTT=5000; $r=3\%$)	96
Figura 39 – Índice de confiabilidade ao longo do tempo (caso 4)	113
Figura 40 – Índice de confiabilidade ao longo do tempo (caso 5)	113
Figura 41 – Índice de confiabilidade ao longo do tempo (caso 6)	114
Figura 42 – Índice de confiabilidade ao longo do tempo (caso 7)	114
Figura 43 – Índice de confiabilidade ao longo do tempo (caso 8)	115

Lista de Tabelas

Tabela 1 – Valores do coeficiente de fadiga A e CAFL para cada categoria de detalhe (AASHTO, 2012)	30
Tabela 2 – Fator de modificação α e coeficiente B_x para as categorias de detalhes estruturais da AASHTO (Hosseini et al., 2013)	36
Tabela 3 – Coeficientes C_A e C_B para o aço carbono (Kayser & Nowak, 1989)	38
Tabela 4 – Dados de corrosão com aplicação de lavagem periódica em aços carbono (adaptado de Yanez, 2016)	40
Tabela 5 – Funções de ativação	46
Tabela 6 – Propriedades dos materiais (adaptado de Chung & Sotelino, 2005)	57
Tabela 7 – Resultados de validação do modelo	61
Tabela 8 – Parâmetros de geometria (tabuleiro)	63
Tabela 9 – Parâmetros de material	63
Tabela 10 – Parâmetros de geometria – dimensões da viga de aço	65
Tabela 11 – Atributos da RNA	68
Tabela 12 – Experimentos	71
Tabela 13 – Subconjunto de atributos selecionados	76
Tabela 14 – Configurações de RNA que apresentaram os melhores resultados em cada subconjunto de atributos	78
Tabela 15 – Parâmetros estatísticos das variáveis A e Δ	81
Tabela 16 – Parâmetros do modelo de corrosão (cenário sem manutenção)	82
Tabela 17 – Parâmetros do modelo de corrosão (cenários com manutenção)	82
Tabela 18 – Fração de caminhões (ft) no volume de tráfego de acordo com classificação da ponte (tabela C3.6.1.4.2-1 AASHTO).	86
Tabela 19 – Taxa de ocupação em uma única faixa (p) de acordo com o número de faixas (tabela 3.6.1.4.2-1 AASHTO)	86
Tabela 20 – Dados da ponte considerada	91

Tabela 21 – Parâmetros variados em cada conjunto de simulação	91
Tabela 22 – Tempo de vida útil (conjunto de simulação 1)	92
Tabela 23 – Tempo de vida útil (conjunto de simulação 2, experimento 1: $r=3\%$)	93
Tabela 24 – Tempo de vida útil (conjunto de simulação 2, experimento 2: $r=5\%$)	94
Tabela 25 – Tempo de vida útil (ADTT=5000; $r=3\%$)	96
Tabela 26 – Resultados do subconjunto de atributos 1	108
Tabela 27 – Resultados do subconjunto de atributos 2	108
Tabela 28 – Resultados do subconjunto de atributos 3	109
Tabela 29 – Resultados do subconjunto de atributos 4	109
Tabela 30 – Resultados do subconjunto de atributos 5	110
Tabela 31 – Resultados do subconjunto de atributos 6	110
Tabela 32 – Matriz dos pesos da primeira camada, W_1	111
Tabela 33 – Matriz dos pesos da segunda camada, W_2	112
Tabela 34 – Vetor de Viés da primeira camada, b_1	112
Tabela 35 – Vetor de Viés da segunda camada, b_2	112
Tabela 36 – Tempo de vida útil (caso 4)	113
Tabela 37 – Tempo de vida útil (caso 5)	114
Tabela 38 – Tempo de vida útil (caso 6)	114
Tabela 39 – Tempo de vida útil (caso 7)	115
Tabela 40 – Tempo de vida útil (caso 8)	115

Lista de Abreviações

AASHTO	<i>American Association of State Highway Transportation Officials</i>
ACI	<i>American Concrete Institute</i>
ADT	<i>Average Daily Traffic</i> (volume de tráfego médio diário)
ADTT	<i>Average Daily Truck Traffic</i> (volume de tráfego médio diário de caminhões)
$ADTT_{SL}$	<i>Average Daily Truck Traffic in a Single Lane</i> (volume de tráfego médio diário de caminhões em uma única faixa)
ASCE	<i>American Society of Civil Engineers</i>
CAFL	<i>Constant Amplitude Fatigue Limit</i>
CNF	<i>Corrosion Notch Factor</i> (Fator de entalhe de corrosão)
EF	Elementos finitos
FHWA	<i>Federal Highway Administration</i>
FNF	<i>Fatigue Notch Factor</i> (Fator de entalhe de fadiga)
IA	Inteligência Artificial
LEFM	<i>Linear Elastic Fracture Mechanics</i>
MAPE	Mean Absolute Percentage Error (erro percentual absoluto médio)
MEF	Método dos Elementos Finitos
ML	<i>Machine Learning</i>
MLP	<i>Multilayer Perceptron</i>
MSE	<i>Mean Squared Error</i> (erro quadrático médio)
NAF	<i>Nominal Amplification Factor</i> (fator de amplificação da tensão nominal)
RNA	Rede Neural Artificial
SGD	<i>Stochastic Gradient Descent</i> (Gradiente Descendente Estocástico)
SHM	<i>Structural Health Monitoring</i>
SSE	<i>Sum of Squared Error</i> (soma do erro quadrático)
SVM	<i>Support Vector Machine</i>
WIM	<i>Weigh in Motion</i>

Lista de símbolos

$\Delta\sigma$	Faixa de variação de tensão
N	Número de ciclos até a falha
A	Coeficiente de resistência à fadiga
m	Coeficiente de fadiga associado à inclinação da curva S-N
D	Dano acumulado
n_i	Número de ciclos aplicados para cada faixa de tensão $\Delta\sigma_i$
N_i	Número de ciclos até a falha para cada faixa de tensão $\Delta\sigma_i$
$\Delta\sigma_e$	Faixa de tensão equivalente de amplitude constante
$\Delta\sigma_{ei}$	Intervalo de faixa de tensão em um histograma de tensões
γ_i	Frequência de ocorrência da faixa de tensão $\Delta\sigma_{ei}$
W_{eq}	Peso de um caminhão equivalente
W_i	Intervalo de peso dos caminhões
f_i	Porcentagem de caminhões dentro de um intervalo de peso W_i .
$\Delta\sigma_s^c$	Tensão nominal da seção corroída
$\Delta\sigma_s$	Tensão nominal antes da corrosão
$\Delta\sigma_x$	Faixa de tensão nos locais de descontinuidades do detalhe estrutural de um metal não corroído
$\Delta\sigma_{x,corr}$	Faixa de tensão nos locais de descontinuidades do detalhe estrutural de um metal com corrosão
B_X	Coeficiente da regressão linear da equação de <i>CNF</i>
$R(t)$	Penetração média da corrosão em μm no ano t
C_A	Coeficiente de corrosão (μm)
C_B	Coeficiente de corrosão (adimensional)
t	Número de anos
t_i	Tempo de vida útil do sistema de revestimento/ início da corrosão (anos)
Q	Função de distribuição de probabilidade do carregamento
R	Função de distribuição de probabilidade da resistência
\bar{R}	Média da resistência
\bar{Q}	Média do carregamento
$\beta(t)$	Índice de confiabilidade no tempo
β_{alvo}	Índice de confiabilidade alvo

P_f	Probabilidade de falha
Φ	Função de distribuição acumulada normal padrão
σ	Desvio Padrão
μ	Média
V	Coefficiente de variação
$g(t)$	Função de estado limite em função do tempo
Δ	Acúmulo de dano crítico de Miner
$D(t)$	Dano acumulado no tempo
$N(t)$	Número de ciclos no ano t
r	Taxa de crescimento anual do tráfego de veículos
λ_x e ζ_x	Parâmetros da distribuição lognormal
w_{ij}	Peso do neurônio i com sinal de entrada j
x_i	Sinais de entrada da RNA
φ	Função de ativação
y_j	Sinais de saída da RNA
v_j	Bloco de soma do modelo RNA
Δw_{ij}	Ajuste (variação) dos pesos na fase de retropropagação
η	Taxa de aprendizado
R^2	Coefficiente de determinação
R_{adj}^2	Coefficiente de determinação ajustado
Y_i	Valor real
\hat{Y}_i	Valor previsto
\bar{Y}_i	Média das observações
n	Número de amostras
k	Número de variáveis independentes
SS_{tot}	Soma total dos quadrados
SS_{exp}	Soma dos quadrados explicada
E	Módulo de Elasticidade
f_{ck}	Resistência à compressão do concreto
h_w	Altura da alma
t_w	Espessura da alma
b_f	Largura das mesas

b_{fc}	Largura da mesa de compressão (superior)
b_{ft}	Largura da mesa de tração (inferior)
t_f	Espessura das mesas
I_{yc}	Momento de inércia da mesa de compressão (superior)
I_{yt}	Momento de inércia da mesa de tração (inferior)
x_n	Valor normalizado
x	Valor do dado real
x_{max}	Valor máximo do dado real
x_{min}	Valor mínimo do dado real
$W_{ij}^{[L]}$	Matriz dos pesos da camada L com dimensão $(n^{[L]}, n^{[L-1]})$; relaciona o neurônio i da camada $[L - 1]$ com o neurônio j da camada $[L]$
$n^{[L]}$	Número de neurônios da camada L
$b_j^{[L]}$	Vetor de viés da camada L com dimensão $(1, n^{[L]})$ associado ao neurônio j da camada $[L]$
$X_i^{[0]}$	Matriz da camada de entrada (zero) com dimensão $(1, n_x)$
n_x	Número de atributos
$\varphi^{[L]}$	Função de ativação da camada L
$h_j^{[1]}$	Vetor dos neurônios da primeira camada (camada escondida) com dimensão $(1, n^{[1]})$
$\hat{y}_k^{[2]}$	Vetor da camada de saída (tensão unitária máxima prevista com valor normalizado)
σ_{corr}	Tensão máxima da viga com corrosão
σ_0	Tensão máxima da viga sem corrosão
W_0	Módulo de resistência inferior da seção sem corrosão
W_{corr}	Módulo de resistência inferior da seção corroída
$\sigma_{unit\ máx}$	Tensão unitária máxima
$P_{caminhão}$	Peso do caminhão de fadiga
f_t	Fração de caminhões no tráfego
p	Fator para estimar o volume de tráfego médio diário de caminhões em uma única faixa ($ADTT_{SL}$)

*A mente que se abre a uma nova ideia jamais
volta ao seu tamanho original*

Albert Einstein

1

Introdução

1.1

Motivação

Pontes e viadutos desempenham papel fundamental no desenvolvimento econômico e social de uma região. Tais estruturas estão sujeitas, principalmente, aos mecanismos de deterioração por fadiga e corrosão, devido aos efeitos provocados pelo tráfego de veículos e agressividade do meio ambiente (Kayser & Nowak, 1989). Nesse contexto, atividades de inspeção e manutenção são realizadas para manter o desempenho dessas estruturas dentro de um limite aceitável. Dessa forma, gestores de sistemas de infraestrutura devem implementar diversas estratégias para garantir a manutenção da funcionalidade dessas estruturas ao longo do tempo de acordo com os recursos disponíveis. (Frangopol & Soliman, 2016).

Várias metodologias foram propostas para avaliar a integridade de pontes, com a consideração de diferentes variáveis. Dentre elas, pode-se citar os sistemas baseados em inspeções visuais relacionadas com estados de condições discretas e um modelo de deterioração de Markov com probabilidades de transição estacionárias, como o sistema de gerenciamento de pontes PONTIS (Thompson et al., 1998) e BRIDGIT (Hawk & Small, 1998) utilizados nos Estados Unidos. O modelo de Markov não considera incertezas associadas ao processo de deterioração, assim como os efeitos das intervenções realizadas (Orcesi et al, 2010).

No sistema de monitoramento de integridade estrutural (conhecido também como *Structural Health Monitoring – SHM*, em inglês), a instrumentação da estrutura por sensores registra dados como tensão e deformação periodicamente e permite o acompanhamento e avaliação do desempenho estrutural de pontes a longo prazo, de forma a detectar possíveis danos ainda no estágio inicial (Finotti et al., 2019). Esse sistema, entretanto, tem um custo elevado e acaba sendo mais apropriado para estruturas recém-construídas (Lu et al., 2016). Como alternativa, pesquisas foram realizadas com a integração de um sistema de pesagem em movimento WIM (*Weigh In Motion*, em inglês), que fornece dados de carregamento

móvel, com a modelagem estrutural em elementos finitos (Cha et al., 2016; Guo et al., 2012; Kwon & Frangopol, 2010; Wang et al., 2018) e modelos preditivos (Lu et al., 2019; Lu et al., 2016; Zhu & Zhang, 2018) para avaliação do tempo de vida útil das estruturas.

Em grande parte desses estudos, a segurança da estrutura ao longo do tempo é avaliada em termos do índice de confiabilidade estrutural, de forma a considerar as incertezas inerentes às variáveis dos modelos de deterioração. A utilização de uma abordagem probabilística permite tratar a variação dos parâmetros de resistência e solicitação nos modelos de maneira mais racional e científica (Ang & De Leon, 2005). Assim, o acompanhamento do desempenho estrutural ao longo do tempo na gestão de um sistema de infraestrutura possibilita o planejamento de ações que garantam a segurança e operação dessas estruturas.

1.2 Objetivo

Tendo em vista que não são raros os casos em que os registros quanto a condição da estrutura são escassos, que o acesso aos dados de pesagem em movimento são limitados e que a implantação de sistemas de monitoramento estrutural podem representar um custo elevado, este trabalho tem o objetivo de desenvolver uma metodologia para estimar o tempo de vida útil de pontes de aço-concreto de um único vão. Tal estimativa considera os danos por fadiga e corrosão a partir de uma análise de confiabilidade estrutural sob diferentes cenários, com ausência ou presença de atividades de manutenção.

1.3 Escopo

O processo de corrosão-fadiga em pontes de aço é um mecanismo complexo e pouco compreendido devido a diversas variações e incertezas nos parâmetros envolvidos no processo. Assim, esse estudo se limitou à avaliação de pontes de aço simplesmente apoiadas com vigas soldadas produzidas com aço-carbono e protegidas com um sistema de revestimento de três camadas. Para análise da fadiga, considerou-se a degradação provocada pela passagem de um veículo de fadiga da norma americana (AASHTO). Em relação à degradação provocada pelo meio ambiente, considerou-se apenas o efeito da corrosão uniforme em três macro

ambientes: rural, urbano/ industrial e marinho. Além disso, as atividades de manutenção consideradas no sistema afetam apenas a degradação por corrosão e seus custos não estão contemplados no sistema proposto.

Para cumprir o objetivo proposto, foram realizadas as seguintes tarefas:

- Validação do modelo em elementos finitos utilizado para obter as tensões nas vigas da ponte de aço sob o carregamento móvel.
- Elaboração de uma base de dados com diferentes configurações de pontes de aço e simulação do comportamento dessas estruturas utilizando o modelo em elementos finitos validado.
- Seleção de um modelo de rede neural para substituir a análise estrutural em elementos finitos no sistema proposto.
- Treinamento e validação da rede neural selecionada usando a base de dados elaborada para estimar a tensão nas vigas de pontes de aço a partir das características geométricas e de material da estrutura.
- Avaliação da segurança estrutural de vigas de pontes de aço simplesmente apoiadas a partir de uma análise de confiabilidade para fadiga, considerando as incertezas do modelo de deterioração adotado. Inclusão da corrosão na análise de confiabilidade a partir de ajustes nos parâmetros de fadiga do modelo afetados pela corrosão.
- Elaboração do fluxograma do protótipo de um sistema de manutenção para estimar o tempo de vida útil de uma ponte de aço.
- Simulação de uma ponte de aço-concreto típica para avaliar os efeitos dos parâmetros de tráfego e do ambiente na durabilidade da estrutura.

1.4

Estrutura do trabalho

Este documento está dividido em cinco capítulos. O capítulo um descreve a motivação, os objetivos e a metodologia da pesquisa. O capítulo dois apresenta o referencial teórico dos assuntos utilizados para o desenvolvimento da pesquisa. O capítulo três apresenta as etapas necessárias para a elaboração da metodologia proposta, contemplando a análise de modelos em elemento finitos, elaboração de um modelo de rede neural e análise de confiabilidade estrutural. Este capítulo também apresenta o fluxograma desenvolvido para a elaboração da ferramenta de

manutenção. O capítulo quatro apresenta um exemplo numérico de uma ponte de aço típica simplesmente apoiada, com os resultados e discussões de cada conjunto de simulações. O capítulo cinco relata as conclusões encontradas no decorrer da pesquisa e sugere temas para trabalhos futuros.

2 Referencial Teórico

2.1 Fadiga

De acordo com um estudo realizado pela *American Society of Civil Engineers* ASCE (Liu et al., 2016; ASCE Committee on Fatigue and Fracture Reliability, 1982), cerca de 80-90% das falhas em estruturas metálicas estão associadas à fadiga. A fadiga pode ser definida como um processo localizado e progressivo no qual os danos estruturais se acumulam continuamente devido à aplicação repetitiva de cargas dinâmicas externas, como veículos para pontes rodoviárias, podendo levar a falha do material sob uma tensão inferior à tensão de escoamento (Ye et al., 2014). Regiões com concentração de tensões, onde existe uma fratura ou defeito inicial (como em regiões de soldas), causam a formação de uma zona plástica na ponta da trinca (Frangopol et al., 2016), que induzem a danos permanentes no material (Leitão, 2014). A iniciação e propagação de trincas na zona plástica ocorre devido ao dano acumulado causado pelo aumento do número de ciclos de carregamento que, eventualmente, pode causar a ruptura do material (Frangopol et al., 2016).

Apesar de ser uma das formas mais críticas de dano e principal modo de falha para estruturas de aço, o processo de fadiga ainda é pouco compreendido em termos da causa da formação e do mecanismo de falha (Ye et al., 2014). Diversos estudos buscaram estabelecer metodologias para análise do dano por fadiga. Dentre as metodologias atuais de análise de fadiga, destaca-se a abordagem das curvas S-N (tensão em função do número de ciclos do carregamento dinâmico) e da mecânica da fratura elástica linear (*Linear Elastic Fracture Mechanics* – LEFM). A abordagem da LEFM é muito utilizada para o estudo da propagação de fissuras de um detalhe estrutural que apresenta algum dano. Já as curvas S-N são baseadas em dados experimentais, sendo uma das metodologias mais utilizadas em diversos códigos normativos. A última abordagem é a mais apropriada para o objetivo do presente trabalho e é, portanto, a que foi adotada.

2.1.1 Curvas S-N

Os efeitos da fadiga no material dependem do tipo do detalhe estrutural, da magnitude da faixa de tensão e do número de ciclos dessa faixa de tensão (Russo et al., 2016). Na análise de fadiga, a resistência é definida como a capacidade da estrutura de resistir determinado número de ciclos para determinada faixa de tensão. Para vigas de aço, o número de ciclos de carga até a falha pode ser determinado a partir das curvas S-N (Szerszen et al., 1999). Diversas especificações normativas utilizam essa abordagem para o projeto e avaliação da fadiga devido à sua simplicidade e concordância suficiente com os resultados dos testes experimentais (Frangopol et al., 2016).

A abordagem S-N fornece uma relação linear entre o logaritmo da faixa de tensão e o logaritmo do número esperado de ciclos até a falha (Figura 1) para vários tipos de detalhes estruturais. A curva S-N de determinado detalhe é obtida a partir de ensaios em laboratório de várias amostras submetidas a diferentes carregamentos flutuantes de amplitudes constantes até que uma trinca com tamanho predefinido se propague através do detalhe. O número de ciclos até a falha é plotado em relação à faixa de tensão aplicada de cada amostra, e a análise de regressão é realizada para plotar a linha S-N média em escala logarítmica (Frangopol et al., 2016). Se a faixa de variação de tensão provocada pelo carregamento de amplitude constante estiver abaixo da resistência limite de fadiga, indicada pela linha horizontal tracejada da Figura 1, diz-se que, teoricamente, um número infinito de ciclos poderá ocorrer sem a ruptura.




Figura 1 – Exemplo esquemático de uma curva S-N (adaptado de Leitão, 2014)

A relação empírica estabelecida a partir de experimentos entre a faixa de variação de tensão ($\Delta\sigma$) e o número de ciclos até a falha (N), é definida pela

equação (1), em que A é a constante que representa a influência do detalhe estrutural e m é o coeficiente associado à inclinação da reta dos valores médios experimentais. Na equação, $\log(A)$ e m são, respectivamente, a interseção no eixo $\log(N)$ e o inverso da inclinação da reta obtida a partir da análise de regressão (Grubb et al., 2015).

$$\log N = \log A - m \cdot \log \Delta\sigma \quad \text{ou} \quad N = A \cdot \Delta\sigma^{-m} \quad (1)$$

2.1.2

Acúmulo de Dano – Palmgreen-Miner

As curvas S-N são baseadas em testes com carregamento de amplitude constante. No entanto, a maioria dos componentes estruturais de pontes são submetidos a carregamentos variáveis devido a diferentes configurações de caminhões e combinações de carregamento (Russo et al., 2016). Assim, o dano por fadiga devido a tensões de amplitude variável geralmente é quantificado pela a regra do acúmulo de dano de Miner (Miner, 1945), em que o dano por fadiga é acumulado de forma linear segundo a expressão dada pela equação (2).

$$D = \sum_{i=1}^n \frac{n_i}{N_i} \quad (2)$$

Onde N_i é o número de ciclos até a falha, n_i é o número de ciclos aplicados e n é o número de intervalos de tensão em um histograma de tensões. Nesse modelo, a falha do detalhe ocorre quando $D = 1$. É importante observar que essa abordagem negligencia o efeito da sequência de carregamento, ou seja, a ordem na qual os ciclos são aplicados. No entanto, para a maioria dos problemas de engenharia estrutural, esse modelo é suficiente para obter uma precisão razoável (Fisher et al., 1998).

2.1.3

Análise de fadiga segundo normas de projeto

De forma geral, as normas de projeto recomendam a aplicação das curvas S-N associadas à regra do acúmulo de dano de Miner. A análise de resistência à fadiga é feita a partir da faixa de variação de tensão – diferença algébrica entre a tensão máxima e a tensão mínima para cada ciclo de carga em um detalhe (Grubb et al., 2015), representada na Figura 2 – na qual apenas o carregamento variável com o coeficiente de impacto são considerados; o carregamento permanente não contribui para a faixa de tensão. Essa faixa de tensão pode ser obtida a partir da análise

estrutural das tensões em um detalhe com a passagem de um trem-tipo estabelecido em cada norma, ou através de históricos de tensão obtidos a partir de estações de pesagem em movimento (*Weigh In Motion*, WIM, em inglês), onde é necessário adotar um método para a contagem do número de ciclos, como o método *rainflow*.




Figura 2 – Faixa de tensão de um detalhe estrutural (adaptado de Grubb et al., 2015)

No Brasil, não existe uma norma específica para avaliação da fadiga em pontes de aço. A norma NBR 8800 (2008) cobre apenas o dimensionamento de edifícios em estrutura metálica ou mista. Normas estrangeiras específicas para pontes como a AASHTO (2012), EUROCODE 3 (2005) e BS5400 (1980) apresentam metodologias baseadas na tensão nominal de vida útil para o dimensionamento e verificação à fadiga. Apesar do reconhecimento de algumas diferenças na avaliação da fadiga entre essas normas, neste trabalho será abordado apenas os critérios de avaliação adotados pela norma americana (AASHTO, 2012) com enfoque para análise de fadiga induzida por carregamento.

A Figura 3 mostra as curvas S-N adotadas pela norma americana AASHTO (2012) para detalhes metálicos soldados. Tais detalhes são divididos em categorias (A, B, B', C, C', D, E e E') e são classificados de acordo com as propriedades geométricas da solda, a direção da tensão aplicada e ao método de fabricação do detalhe (Figura 4).




Figura 3 – Curva S-N da (AASHTO, 2012)




Figura 4 – Exemplos de detalhes Estruturais: (a) Solda da mesa inferior com a alma (Categoria B); (b) solda do enrijecedor transversal (Categoria C’); (AASHTO, 2012)

A análise de regressão linear feita para definir as curvas dos 8 detalhes estruturais compreendidos na norma americana foi obtida a partir da linha paralela à linha de vida média estimada para cada grupo de detalhe com a distância de dois desvios padrões de acordo com Russo et al. (2016). Isso representa o limite de confiança inferior de 95% e define uma probabilidade de falha de 5% (Figura 5).




Figura 5 – Curva S-N esquemática para um detalhe típico na norma AASHTO (adaptado de Chung, 2004)

A faixa de tensão é um dos parâmetros mais significativos na análise da resistência à fadiga devido à existência de tensões residuais de tração em estruturas de aço soldadas. O processo de soldagem resulta em tensões residuais de tração de alta magnitude, devido ao recolhimento da solda após o resfriamento, que ocorrem em qualquer tipo de aço. Além disso, apenas as tensões de tração contribuem para a propagação da fratura, sendo considerados, portanto, apenas ciclos de tensão de tração ou ciclos reversíveis para a análise de fadiga (Grubb et al., 2015).

Na norma americana, a relação entre a resistência nominal à fadiga em termos de faixa de tensão e o número de ciclos para a falha é estabelecida pela equação (1), onde m assume valor igual a 3 para todos os detalhes estruturais, e o valor do coeficiente A para cada categoria é definido conforme a Tabela 1. A linha pontilhada das curvas na Figura 3 representa a faixa de tensão abaixo da qual não há formação de fissuras devido à fadiga sob um carregamento de amplitude

constante. Essa faixa de tensão recebe a denominação de limite de fadiga de amplitude constante, *Constant Amplitude Fatigue Limit* (CAFL), região abaixo da qual o detalhe estrutural tem, teoricamente, vida infinita à fadiga.

Tabela 1 – Valores do coeficiente de fadiga A e CAFL para cada categoria de detalhe (AASHTO, 2012)

Categoria do Detalhe Estrutural	Coeficiente de Resistência à Fadiga, A ksi ³ (MPa ³)	Limite de Fadiga, CAFL ksi (MPa)
A	$250 \cdot 10^8$ ($88 \cdot 10^{11}$)	24 (165)
B	$120 \cdot 10^8$ ($39,3 \cdot 10^{11}$)	16 (110)
B'	$61 \cdot 10^8$ ($20 \cdot 10^{11}$)	12 (82,7)
C	$44 \cdot 10^8$ ($14,4 \cdot 10^{11}$)	10 (69)
C'	$44 \cdot 10^8$ ($14,4 \cdot 10^{11}$)	12 (82,7)
D	$22 \cdot 10^8$ ($7,21 \cdot 10^{11}$)	7 (48,3)
E	$11 \cdot 10^8$ ($3,61 \cdot 10^{11}$)	4,5 (31)
E'	$3,9 \cdot 10^8$ ($1,28 \cdot 10^{11}$)	2,6 (17,9)

Para contabilizar o efeito do carregamento de amplitude variável que normalmente é observado em estruturas de pontes, utiliza-se a regra do acúmulo de dano ou de Miner. De acordo com os resultados do estudo de Schilling et al. (1978), os pesquisadores definiram que uma faixa de tensão equivalente de amplitude constante pode ser definida como mostra a equação (3), assumindo o coeficiente m de fadiga igual a 3.

$$\Delta\sigma_e = \sqrt[3]{\sum \gamma_i \Delta\sigma_{ei}^3} \quad (3)$$

Onde $\Delta\sigma_e$ é a faixa de tensão equivalente de amplitude constante, ou faixa de tensão efetiva, e γ_i é a frequência de ocorrência da faixa de tensão $\Delta\sigma_{ei}$. O uso dessa faixa de tensão equivalente permite que dados de fadiga e resistência de amplitude constante sejam usados para definir condições de amplitude variável, além de permitir que o dano à fadiga devido a um espectro de carga arbitrário seja relacionado a uma única faixa de tensão. De forma análoga ao cálculo da faixa de tensão, Moses et al. (1987) definiram que o peso de um caminhão equivalente, W_{eq} , pode ser calculado usando a equação (4):

$$W_{eq} = \left(\sum f_i W_i^3 \right)^{1/3} \quad (4)$$

Onde f_i é a porcentagem de caminhões dentro de um intervalo de peso, W_i . Assim, o dano por fadiga causado por um determinado número de passagens desse caminhão equivalente representa o mesmo dano por fadiga causado por um número

igual de passagens de caminhões com pesos diferentes em um fluxo de tráfego real. A faixa de tensão causada pela passagem desse veículo equivalente corresponde à faixa de tensão equivalente dada pela equação (3).

O uso da equação (4) requer a obtenção de um histograma do peso dos caminhões que trafegam em determinado local específico. Como esses tipos de dados geralmente não estão disponíveis, a AASHTO recomenda a aplicação de um carregamento de fadiga, composto pela passagem de único veículo em uma única faixa, já que segundo dados da pesquisa do SHRP2 Project R19B (Modjeski & Masters, 2015; Russo et al., 2016), há um número muito pequeno de caminhões de peso e configuração semelhantes que viajam estreitamente na mesma faixa ou em faixas adjacentes.

O modelo de caminhão equivalente utilizado pela AASHTO é baseado no espectro de peso bruto de veículos de uma pesquisa que utilizou dados de pesagem em movimento conduzida pela *Federal Highway Administration* (FHWA) em 1981 (Chung, 2004; Snyder et al., 1985). Esse modelo busca aproximar o espaçamento e a distribuição do carregamento nos eixos de caminhões de quatro a cinco eixos, visto que são os veículos mais frequentes nas pontes rodoviárias dos Estado Unidos. Assim, o caminhão de projeto de fadiga adotado pela AASHTO (2012) pesa 72 kips (320 kN), com espaçamento e carregamento dos eixos representados pela Figura 6.




Figura 6 – Caminhão para análise da fadiga (adaptado de Grubb et al., 2015)

Para a análise de fadiga, a faixa de tensão equivalente é obtida pela passagem de um caminhão de projeto de fadiga fatorado com peso de 54 kips (240 kN) mais o fator de impacto, o que representa a combinação de carga “*Fatigue IP*” adotada na AASHTO (2012) para o caso de vida finita à fadiga – quando a faixa de tensão equivalente no detalhe estrutural é maior do que o limite de fadiga de amplitude constante (CAFL). Nessa combinação, o fator de combinação de carga é 0,75 ($0,75 \cdot 72 = 54$ kips). O fator de impacto de 1,15 aplicado no carregamento móvel é adotado para considerar os efeitos dinâmicos relacionados com as características da

suspensão do veículo, rugosidade da superfície do pavimento e do acesso da ponte, e a frequência natural da ponte (Grubb et al., 2015).

2.2

Corrosão-fadiga

Corrosão-fadiga se refere à interação entre um ambiente corrosivo e aplicação de tensões cíclicas repetitivas. Segundo Stephens et al. (2001), a interação desses fenômenos de deterioração é mais prejudicial do que qualquer um deles agindo separadamente. Um ambiente corrosivo pode diminuir as propriedades de fadiga de qualquer material, já que a falha em um determinado nível de tensão geralmente ocorre em menos ciclos e não se observa uma resistência limite de fadiga (Revie & Uhlig, 2008). As pontes rodoviárias são extremamente vulneráveis à ação conjunta de fadiga e corrosão devido à natureza do carregamento atuante e à sua exposição ao ar e à umidade.

Componentes estruturais de pontes de aço estão suscetíveis à corrosão quando expostos às condições atmosféricas locais, principalmente devido à presença de umidade e oxigênio em contato com a superfície do metal. De acordo com Nowak & Szerszen (2001), a principal causa de corrosão em pontes de aço é o acúmulo de água e sal (ambiente marinho e sal de degelo). Albrecht & Naeemi (1984), Kayser & Nowak (1989) e Czarnecki (2006) apontaram que outro fator que contribui para a corrosão das vigas de aço é o acúmulo de detritos nas superfícies horizontais desses elementos, já que esses detritos são capazes de reter umidade e compostos poluentes em contato com a superfície do aço por longos períodos.

A corrosão pode causar aumento da tensão e mudança nas propriedades geométricas do elemento estrutural (Kayser & Nowak, 1989). Essa mudança está associada à perda do material que pode estar em um nível microscópico local, como a corrosão por pites, ou em uma área geral como a corrosão superficial. A corrosão por pites gera pontos de descontinuidades locais que podem agir como concentradores de tensões, aumentando a sensibilidade à fadiga do material. A corrosão superficial ou uniforme causa a perda de seção (espessura) das peças, o que ocasiona a redução de propriedades geométricas importantes para a resistência axial e à flexão do material.

Com a aplicação de milhões de carregamentos cíclicos, como é o caso das pontes, a corrosão pode reduzir a resistência a fadiga dos elementos estruturais,

especialmente em regiões onde concentram-se os maiores valores de tensões (Yanez, 2016). Em estudo com testes de fadiga em longarinas corroídas, Albrecht & Lenwari (2008) relataram que todas as trincas de fadiga que se formaram durante os testes foram iniciadas em pites de ferrugem, reentrâncias, costuras mecânicas da laminação e em entalhes formados pela corrosão, concluindo que a corrosão afeta significativamente a resistência à fadiga do material. A partir de estudos semelhantes, Zuraski & Johnson (1990), Hahin (1994), Albrecht & Lenwari (2009) e El Aghoury & Galal (2014) observaram o mesmo comportamento do aço submetido a ambos mecanismos de deterioração.

A seguir, apresenta-se uma revisão sobre alguns métodos desenvolvidos para quantificar a perda da resistência à fadiga devido à corrosão. Além disso, aborda-se também modelos de corrosão encontrados na literatura para estimar a penetração e padrão da corrosão em pontes de vigas de aço.

2.2.1

Métodos para quantificar a perda de resistência à fadiga devido à corrosão

A corrosão-fadiga é um fenômeno complexo extremamente dependente das características do material e do ambiente no qual a estrutura está inserida. Para o dimensionamento de estruturas, há uma escassez de modelos com abordagens simples para avaliar a vida em fadiga de peças de aço corroídas. Isso se deve principalmente à complexidade do problema e da escassez de dados experimentais sobre elementos estruturais carregados ciclicamente sob efeitos ambientais simultâneos de corrosão (El Aghoury & Galal, 2014). Apesar disso, alguns autores buscaram propor metodologias para a avaliação da viga em fadiga de membros de aço corroídos sem precisar recorrer a detalhes como o tamanho, iniciação ou fases de propagação da fratura que são utilizados na solução dada pela mecânica da fratura.

El Aghoury & Galal (2014) buscaram desenvolver um modelo de corrosão-fadiga que pode ser calibrado com base nas propriedades do material e da corrosividade do meio ambiente. A partir desses dados, o modelo fornece a previsão de vida em fadiga, dada em intervalos, com valores máximos e mínimos. Para o desenvolvimento da metodologia, os autores usaram dados experimentais de tensão, número de ciclos para falha, taxa e penetração da corrosão do estudo de Albrecht

& Shabshab (1994) do aço tipo Corten (ou patinável). De acordo com os resultados, os autores relatam que a abordagem proposta mostra uma concordância relativamente boa em relação aos dados experimentais encontrados na literatura e que, porém, é necessário realizar outros trabalhos experimentais para calibrar a função proposta para outros tipos de aço.

No estudo patrocinado pelo departamento de transporte de Illinois (Hahin, 1994), propôs-se uma equação geral de corrosão-fadiga baseada na equação (1) que considera os efeitos da corrosão no cálculo do número de ciclos de tolerados de um detalhe estrutural. Para isso, realizou-se um ajuste na faixa de tensão ($\Delta\sigma$) a partir da redução no momento de inércia ou na área da seção transversal causada pela corrosão, além de um ajuste no coeficiente de resistência a fadiga (A) por um fator (K_f), definido pela razão entre a faixa de tensão real de uma área corroída e a faixa de tensão nominal (calculada) para a área não corroída. O valor desse fator é uma função linear da penetração da corrosão, obtida a partir do ajuste dos dados experimentais realizados nesse estudo. É importante mencionar que os testes realizados por esse estudo compreenderam apenas materiais com detalhes estruturais da categoria A e B da AASHTO, porém o modelo de Hahin (1994) foi utilizado por algumas pesquisas encontradas na literatura para avaliar o dano por corrosão-fadiga em pontes de aço (Deng et al., 2019; Zhang & Yuan, 2014).

Em outro estudo, Hosseini et al. (2013) também propuseram uma metodologia para considerar os efeitos simultâneos da deterioração de pontes de aço devido à fadiga e à corrosão. Tais efeitos foram quantificados por fatores de amplificação da tensão nominal, *Nominal Amplification Factor* (NAF), e de entalhe de corrosão, *Corrosion Notch Factor* (CNF). Diferentemente dos estudos mencionados anteriormente, os autores buscaram aplicar a metodologia proposta para todas as categorias de fadiga estabelecidas pela AASHTO. Dessa forma, devido à sua abrangência, esta será a metodologia adotada para a análise da corrosão-fadiga neste trabalho. Os detalhes deste método são descritos a seguir.

Como mencionado previamente, a ação da corrosão uniforme causa perda de material da seção de um elemento de aço estrutural ao longo do tempo, o que ocasiona um aumento da faixa de tensão, considerando que o carregamento móvel permaneça o mesmo. No estudo de Hosseini et al. (2013), o aumento de tensão devido à perda de material foi mensurado pelo fator de amplificação nominal (NAF), definido como a razão entre a tensão nominal da seção corroída, $\Delta\sigma_s^c$, e a

tensão nominal antes da corrosão, $\Delta\sigma_s$. O NAF é calculado em função do padrão de corrosão (regiões da seção sujeitas ao ataque de corrosão) e da penetração média da corrosão. Assim, esse fator depende da redução nas propriedades geométricas da seção estrutural ao longo do tempo, representando o aumento de tensão nominal devido à essa redução. A determinação da tensão $\Delta\sigma_s^c$ muitas vezes requer a elaboração de modelos em elementos finitos detalhados. Em algumas estruturas, porém, a tensão nominal é inversamente proporcional a área da seção e NAF pode ser expresso por:

$$NAF = \frac{\Delta\sigma_s^c}{\Delta\sigma_s} = \frac{\text{Área da seção antes da corrosão}}{\text{Área da seção após a corrosão}} \quad (5)$$

Além da perda de material, a corrosão causa pites e descontinuidades, que atuam como concentradores de tensão. A presença de descontinuidades estruturais (soldas, mudança de seção, pites de corrosão, entre outros) reduz o valor do coeficiente de resistência a fadiga, A . Em detalhes estruturais não corroídos, essa redução foi quantificada pelo fator de entalhe de fadiga, FNF (*Fatigue Notch Factor*, em inglês) e, em detalhes corroídos, pelo fator de entalhe de corrosão, CNF (*Corrosion Fatigue Notch Factor*, em inglês), no estudo de Hosseini et al. (2013) (Figura 7).




Figura 7 – Representação gráfica do fator de entalhe de fadiga (FNF) e fator de entalhe de corrosão (CNF) (adaptado de Hosseini et al., 2013)

O FNF é definido como a razão entre a faixa de tensão de um metal sem descontinuidades e a faixa de tensão nos locais de descontinuidades do mesmo metal. Já o CNF é definido como a razão entre a faixa de tensão nos locais de descontinuidades do detalhe estrutural de um metal não corroído, $\Delta\sigma_x$, e a faixa de tensão do mesmo metal com corrosão sob as mesmas condições de carregamento e

número de ciclos, $\Delta\sigma_{x,corr}$ (Sharifi & Rahgozar, 2009). Tal fator é calculado apenas em função da penetração da corrosão e representa a redução na resistência a fadiga devido a presença da corrosão, de acordo com a equação (6).

$$CNF = \frac{\Delta\sigma_x}{\Delta\sigma_{x,corr}} = \frac{\sqrt[m]{\frac{A_x}{N}}}{\sqrt[m]{\frac{A_{x,corr}}{N}}} = \sqrt[m]{\frac{A_x}{A_{x,corr}}} \rightarrow A_{x,corr} = \frac{A_x}{CNF^m} \quad (6)$$

Onde A_x é o coeficiente de resistência à fadiga da categoria x (referente às categorias definidas na AASHTO), $A_{x,corr}$ é o coeficiente de resistência à fadiga da categoria x com corrosão, N é o número de ciclos até a falha e m é igual a 3.

Diversos estudos experimentais buscaram estabelecer uma expressão para esse fator (CNF), porém tal expressão foi estabelecida apenas para detalhes da categoria A (categoria de fadiga mais resistente). Os autores propuseram, portanto, uma forma de se obter uma expressão equivalente para as outras categorias de detalhes relacionando a expressão da categoria A com um fator de modificação $\alpha_{x,A}$. Para isso, utilizaram uma função para o CNF baseada no melhor ajuste dos dados de alguns estudos realizados por outros autores. A função do fator de entalhe de corrosão é da forma $CNF = 1 + B_x * R$, onde B_x é o coeficiente da regressão linear ($1/\mu\text{m}$) e R é a penetração da corrosão em μm . Os coeficientes B_x estabelecidos nesse estudo estão representados na Tabela 2.

Tabela 2 - Fator de modificação α e coeficiente B_x para as categorias de detalhes estruturais da AASHTO (Hosseini et al., 2013)

	Categorias AASHTO					
	A	B	B'	C	D	E
$\alpha_{x,A}$	1.00	0.68	0.50	0.44	0.26	0.20
B_x	0.41	0.28	0.21	0.18	0.11	0.08

Nesse estudo, os autores relataram que os valores de R são normalmente obtidos a partir de uma função exponencial do tipo $R(t) = C_A \cdot t^{C_B}$, onde os coeficientes desta equação são obtidos a partir de dados experimentais. Ressalta-se que esta função será descrita em maiores detalhes na seção 2.2.2. Para a quantificação dos efeitos de corrosão-fadiga, Hosseini et al. (2013) também ressaltaram que é necessário conhecer a localização da corrosão que pode ser obtida a partir de inspeções visuais ou a partir de referências existentes na literatura. Na seção a seguir, apresenta-se o modelo de corrosão adotado neste trabalho.

2.2.2 Modelo de corrosão para pontes de aço

De acordo com diversos estudos (Czarnecki & Nowak, 2008; Kayser & Nowak, 1989; Park et al., 1998), a corrosão em vigas de pontes de aço de um único vão ocorre predominantemente nas regiões dos apoios devido a vazamentos nas juntas do tabuleiro, e ao longo do comprimento da ponte devido ao acúmulo de sal e poeira na superfície do aço das vigas (Figura 8). Na análise de seu estudo, no entanto, Czarnecki & Nowak (2008) modificaram esse modelo de localização da corrosão, já que existem diversos fatores que influenciam no padrão de corrosão, o que limita a definição de um modelo de corrosão muito detalhado. Dessa forma, os autores assumiram que a corrosão ocorre em toda a superfície da alma e na superfície superior da mesa inferior ao longo de toda a extensão da ponte (Figura 9), em todas as vigas, independente da sua posição na ponte. O modelo simplificado de padrão de corrosão de Czarnecki & Nowak (2008) foi adotado neste trabalho para representar a penetração da corrosão nas vigas de pontes de aço, já que representa um modelo mais geral de corrosão.




Figura 8 – Regiões típicas de corrosão para pontes de aço (adaptado de Kayser, 1988)




Figura 9 – Modelo de padrão de corrosão proposto por Czarnecki (2006)

A corrosão se desenvolve de diversas formas e a corrosão uniforme ou geral é o tipo de corrosão mais comum, que causa uma redução gradual na espessura da seção (Sharifi & Rahgozar, 2009), sendo este o tipo de corrosão abordado neste trabalho. A partir de testes de laboratório realizados em amostras de aços corroídos, definiu-se que a perda de seção do material devido a corrosão segue uma função exponencial do tipo $R(t) = C_A * t^{C_B}$ (Kayser & Nowak, 1989; Komp, 1987), onde $R(t)$ representa a penetração média da corrosão em μm no ano t , t é o número de anos e C_A (μm) e C_B (adimensional) são os parâmetros de corrosão determinados a partir da análise de dados experimentais, que dependem do ambiente no qual o a amostra está inserida.

Para o caso da superestrutura de pontes de aço carbono, Kayser & Nowak (1989) estimaram um valor médio desses parâmetros, como mostra a Tabela 3, onde são considerados ambientes classificados como rural, urbano e marinho. Tais parâmetros foram estimados com base no estudo de Albrecht & Naeemi (1984), obtidos a partir dos dados de testes em amostras de aço realizados em diversos locais dos Estados Unidos, que representam os diferentes ambientes considerados no estudo. Nessa abordagem, os ambientes urbano e industrial foram classificados na mesma categoria, já que ambos apresentam os mesmos compostos corrosivos no ambiente.

Tabela 3 – Coeficientes C_A e C_B para o aço carbono (Kayser & Nowak, 1989)

Ambiente	Aço Carbono	
	C_A	C_B
Rural	34.0	0.65
Urbano	80.2	0.59
Marinho	70.6	0.79

Park et al. (1998) propuseram outro modelo de corrosão representado por três curvas de taxas de corrosão – alta, média e baixa. De acordo com os autores, a taxa de corrosão pode ser considerada praticamente zero nos primeiros 10 a 20 anos, dependendo do ambiente, que corresponde ao período em que a pintura das vigas fornece proteção contra corrosão. Conforme o processo de deterioração começa a se desenvolver na superfície do metal, observa-se um processo de corrosão acelerado (Figura 10). Nesse estudo, o modelo e os parâmetros estatísticos C_A e C_B de Kayser & Nowak (1989) foram utilizados para estimar a penetração da corrosão ao longo do tempo.




Figura 10 - Taxas de corrosão (adaptado de Park et al., 1998)

O estudo de Park et al. (1998) não menciona como a vida útil do revestimento de proteção das vigas é estimado, assim como o tipo de revestimento considerado. O uso de um revestimento de proteção para a superfície do aço em pontes tem sido o método de proteção predominantemente utilizado por departamentos de transportes nos Estados Unidos (Yanez, 2016). Os componentes de tais sistemas evoluíram desde as básicas pinturas à base de chumbo até os modernos sistemas de três camadas, sendo estes últimos os mais recomendados pelos departamentos de transporte estaduais dos EUA. Estudos estimaram que o tempo de vida útil dos sistemas de três camadas utilizados atualmente é de aproximadamente 15, 21 e 30 anos para os ambientes rural, industrial e marinho, respectivamente (Brevoort & Melampy; Shields, 1996; Robert Kogler, 2015). Estes valores foram adotados no modelo de corrosão do presente trabalho. Assim, a função que estima penetração de corrosão ao longo do tempo pode ser representada pela equação (7), onde t_i é o tempo de vida útil do sistema de revestimento, a partir do qual se inicia o processo de corrosão.

$$R(t) = C_A * (t - t_i)^{C_B} \quad (7)$$

A realização periódica de atividades de manutenção pode prolongar a vida útil de pontes a custos relativamente baixos (FHWA, 2018; Yanez, 2016). Assim, tais atividades também podem influenciar no modelo de deterioração do material. No estudo de Yanez (2016), testes de corrosão acelerada (*Accelerated Corrosion Test* – ACT) foram realizados em amostras de aço carbono e aço patinável para comparar a degradação por corrosão sob diferentes alternativas manutenção de lavagem e pintura local do material. De acordo com a análise dos resultados das amostras de aço carbono sem revestimento, apesar de não ser possível estabelecer uma relação clara entre cada alternativa de lavagem do material adotada e a mudança de espessura das amostras, notou-se que as alternativas que apresentavam

regularidade da lavagem entre duas e cinco semanas (média de 3.5 semanas) nos testes ACT provocaram uma redução na taxa de corrosão do material.

Assim, Yanez (2016) estabeleceu uma relação entre o tempo e as medidas de corrosão dos ensaios dessas alternativas e o respectivo tempo e penetração da corrosão de um ambiente real de acordo com o modelo de corrosão de Kayser & Nowak (1989). Os coeficientes obtidos a partir do ajuste dos dados de corrosão desses testes podem ser observado na Tabela 4, assim como a regularidade de lavagem adotada para este cenário. A partir de pesquisa na literatura disponível, Yanez (2016) também estimou que a vida útil do revestimento de proteção pode ser prolongada por cinco a dez anos com a realização da lavagem periódica na superestrutura.

Tabela 4 – Dados de corrosão com aplicação de lavagem periódica em aços carbono (adaptado de Yanez, 2016)

Ambiente	Aço Carbono		
	C_A	C_B	Regularidade da lavagem (anos)
Rural	53.6	0.45	5.72
Urbano/ Industrial	95.2	0.45	1.59
Marinho	93.4	0.45	1.66

2.3

Confiabilidade estrutural

Existem diversas fontes de incertezas inerentes em uma análise estrutural. Isso se deve ao fato de que os parâmetros de resistência e carregamento não são determinísticos, mas aleatórios. Por isso, não se pode garantir sistemas estruturais absolutamente seguros, com probabilidade de falha zero. Assim, a análise de uma estrutura, seja para projeto ou avaliação da vida útil, deve buscar operar com uma probabilidade de falha finita, adotando metodologias baseadas em modelos probabilísticos e confiabilidade estrutural.

A falha na análise de confiabilidade estrutural é baseada no conceito de estado limite, que representa o limite entre o desempenho aceitável e não aceitável da estrutura. Esse limite geralmente é representado matematicamente por uma função de estado limite (Nowak & Collins, 2000). Dada uma curva de distribuição normal para as cargas, Q , e uma para a resistência, R , com valores médios \bar{R} e \bar{Q} , a falha do sistema corresponde à área de sobreposição onde os extremos das distribuições de carga e resistência se cruzam. A função de estado limite é representada pela

curva criada ao subtrair a carga da resistência, isto é, $R - Q$. Dessa forma, a falha corresponde aos valores negativos dessa curva, quando a carga excede a resistência (Russo et al., 2016) – Figura 11.

Para controlar o número de falhas, a média da curva $R - Q$ é deslocada a determinada distância do eixo das ordenadas (probabilidade de ocorrência), definida como β vezes o desvio padrão, σ . Assim, β é definido como índice de confiabilidade, uma medida probabilística de segurança comumente utilizada no projeto e na avaliação estrutural, que está relacionado com a probabilidade de falha (Figura 11). Um β igual a zero (sem deslocamento) indica 50% de chance de falha. Já um β de 3,5, valor alvo comumente utilizado para estados limites de resistência última, corresponde a uma probabilidade de falha de 0,02% (Russo et al., 2016).




Figura 11 – Definição de β usando características estatísticas da resistência e do carregamento (adaptado de Russo et al., 2016)

Metodologias de avaliação da vida em fadiga utilizam o índice de confiabilidade variante no tempo como indicador de performance (Frangopol et al., 2016). Isso se deve ao fato de que a fadiga é um estado limite de serviço, relacionado a uma deterioração gradual, em que a falha desse estado limite é um efeito cumulativo do carregamento variável (Nowak & Collins, 2000). Através da definição de níveis mínimos aceitáveis de confiabilidade, normalmente representados por um valor mínimo de β (β_{alvo}), considera-se que a vida útil à fadiga é atingida quando o nível de confiabilidade atinge seu limite mínimo (Frangopol et al., 2016).

A calibração do estado limite de fadiga da AASHTO LRFD (2012) foi baseada em um nível de confiabilidade representado por um β alvo igual a 1,0; que corresponde a uma probabilidade de falha de aproximadamente 16%. Essa probabilidade representa uma chance muito maior de que o estado limite seja excedido (ou seja, que trincas possam se desenvolver) do que a taxa de falha aceita

no estado limite de resistência última (Russo et al., 2016). Outras referências na literatura consideraram valores diferentes para o índice de confiabilidade alvo para fadiga, variando entre 2 e 4 (Frangopol et al., 2016; Lu et al., 2016; Mansour et al., 1996; Zhu & Zhang, 2018).

A relação entre o índice de confiabilidade, β , e a probabilidade de falha, P_f , é definida matematicamente pela equação (8).

$$\beta = \Phi^{-1}(1 - P_f) \quad (8)$$

Em que Φ^{-1} é o inverso da função de distribuição acumulada normal padrão. Para o caso em que a resistência R e a carga aplicada Q seguem distribuições de probabilidade normais, com variáveis aleatórias não correlacionadas, o índice de confiabilidade é obtido a partir da equação (Nowak & Collins, 2000):

$$\beta = \frac{\mu_R - \mu_Q}{\sqrt{\sigma_R^2 + \sigma_Q^2}} \quad (9)$$

Onde μ_R é o valor médio da resistência; μ_Q é o valor médio do efeito da carga aplicada; σ_R é o desvio padrão de R ; e σ_Q é o desvio padrão de Q . Por outro lado, se a resistência R e a carga aplicada Q seguirem distribuições lognormais, com variáveis aleatórias não correlacionadas, o índice de confiabilidade pode ser aproximado pela equação (10), onde $V_R = \sigma_R/\mu_R$ é o coeficiente de variação de R e V_Q é o coeficiente de variação de Q (Ghosn et al., 2010).

$$\beta = \frac{\mu_{\ln R} - \mu_{\ln Q}}{\sqrt{\sigma_{\ln R}^2 + \sigma_{\ln Q}^2}} = \frac{\ln\left(\frac{\mu_R}{\mu_Q}\right)}{\sqrt{V_R^2 + V_Q^2}} \quad (10)$$

De acordo com os conceitos de estado limite e índice de confiabilidade, é possível encontrar na literatura diversas abordagens para o cálculo do índice de confiabilidade em relação à fadiga. Nowak & Szerszen (2001), Szerszen & Nowak (2000) e Szerszen et al. (1999), estabeleceram a função do estado limite para fadiga em função do número de ciclos de falha e número de ciclos aplicados, que correspondem às variáveis aleatórias de resistência e de solicitação, respectivamente. Rakoczy et al. (2016) definiram a função de estado limite em termos da razão do dano permitido e aplicado, considerando que as variáveis seguem uma função de distribuição normal, conforme verificado na análise estatística feita pelos autores.

Em algumas abordagens mais recentes (Frangopol et al., 2016; Guo et al., 2012; Kwon & Frangopol, 2010), a função do estado limite, $g(t)$, usada para estimar a vida útil à fadiga foi definida em função do dano acumulado, conforme a equação (11).

$$g(t) = \Delta - D(t) \quad (11)$$

Na equação acima, Δ é o acúmulo de dano crítico de Miner, indicando o dano acumulado permitido, e $D(t)$ é o índice de acúmulo de dano de Miner, indicando a demanda. De acordo com o modelo de acúmulo de dano de Miner, a falha dos detalhes ocorre quando $D = 1,0$. No entanto, este valor sofre algumas variações segundo a literatura e, por isso, o índice de acúmulo de dano crítico de Miner é geralmente tratado como uma variável aleatória que segue uma distribuição lognormal (Frangopol et al., 2016), com valor médio de 1,0 e com um coeficiente de variação de 0,3 (Wirsching, 1984).

A partir da combinação das equações estabelecidas pelas curvas S-N (1) e da regra do acúmulo de dano de Miner (26), o dano em função do tempo $D(t)$ pode ser definido pela equação (12).

$$D(t) = \frac{N(t)}{A} \cdot \Delta \sigma_e^m \quad (12)$$

Onde $N(t)$ é o número de ciclos no ano t , A é constante da categoria do detalhe estrutural, $\Delta \sigma_e$ é a faixa de tensão efetiva e m é a inclinação da curva S-N. A partir dessas fórmulas e assumindo que todas as variáveis aleatórias seguem uma função de distribuição lognormal, Frangopol et al. (2016) definiram que o índice de confiabilidade pode ser calculado de acordo com a equação (13).

$$\beta(t) = \frac{\lambda_{\Delta} + \lambda_A - m \cdot \lambda_{\Delta \sigma_e} - \ln N(t)}{\sqrt{\zeta_{\Delta}^2 + \zeta_A^2 + (m \cdot \zeta_{\Delta \sigma_e})^2}} \quad (13)$$

Onde λ_X e ζ_X são parâmetros da distribuição lognormal associados a diferentes variáveis aleatórias (Δ, A e $\Delta \sigma_e$), que podem ser estimados a partir da média (μ_X) e do coeficiente de variação (V_X), conforme as equações (14) e (15).

$$X \rightarrow A, \Delta, \Delta \sigma_e$$

$$\lambda_X = \ln(\mu_X) - 0.5 \zeta_X^2 \quad (14)$$

$$\zeta_X = \sqrt{\ln(1 + V_X^2)} \quad (15)$$

2.4 Redes Neurais

A inteligência artificial (IA) é um ramo da ciência da computação que busca, através de dispositivos computacionais, simular características do comportamento humano tais como aprendizado, raciocínio e reconhecimento de padrões. Dentro dessa ciência está o aprendizado de máquina (*machine learning* ou ML, em inglês), que compreende os métodos (algoritmos) pelos quais as máquinas são treinadas para aprender a partir de dados.

Modelos de ML são classificados de acordo com o tipo de supervisão recebido no treinamento dos dados, sendo que os principais são aprendizado supervisionado e não supervisionado. No aprendizado supervisionado, os dados que alimentam o algoritmo de aprendizado contêm tanto os dados de entrada do modelo (denominados atributos ou preditores) quanto os dados de saída (respostas do modelo). Tais modelos são utilizados, principalmente, para problemas de regressão (predição de um valor) e classificação (predição de uma classe/ categoria). No aprendizado não supervisionado, por sua vez, os dados de treinamento não contêm as respostas no modelo, sendo comumente utilizados para problemas de associação e agrupamento.

Um dos modelos de ML mais utilizados são as redes neurais artificiais (RNA). Inspiradas no funcionamento dos neurônios biológicos, as RNAs são modelos versáteis, poderosos e flexíveis, o que as torna ideais para trabalhar com tarefas altamente complexas em problemas de aprendizado de máquina. A seguir, apresenta-se uma breve descrição do método de Redes Neurais, seus conceitos básicos, arquitetura e topologia, principais algoritmos utilizados e métricas de avaliação.

2.4.1 Unidade de processamento das redes neurais

As RNA foram inspiradas na estrutura do cérebro humano, sendo compostas de elementos processadores com comportamento inspirado em um modelo simplificado do neurônio biológico (Figura 12).

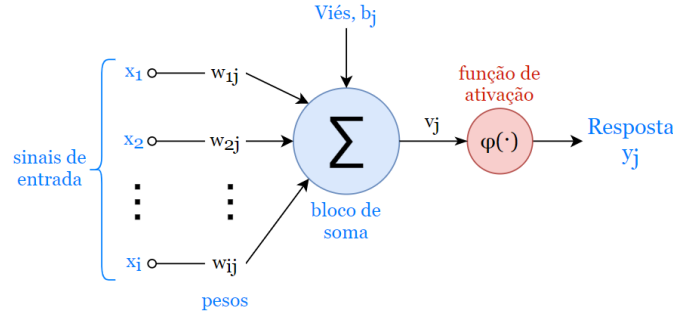


Figura 12 – Neurônio artificial (adaptado de Haykin, 2009)

Assim, uma unidade processadora da RNA é um modelo matemático com n nós de entrada x_i , que recebem as ativações dos neurônios anteriores e apenas um nó de saída, y_j . Os nós de entrada são conectados por links, e cada um possui um peso numérico associado, w_{ij} , em que i é o índice do sinal de entrada e j é o índice do neurônio. No cálculo do modelo, os nós de entrada são multiplicados por seus respectivos pesos e, em seguida, combinados linearmente por uma função de adição. O resultado dessa combinação linear é então submetido a uma função de ativação (φ), que limita a amplitude do valor de saída a algum valor finito (Haykin, 2009). O bloco de soma do modelo (v_j) inclui um parâmetro extra denominado viés (b_j), que tem o efeito de aumentar ou diminuir o valor de entrada na função de ativação. Dessa forma, esse parâmetro auxilia no ajuste da função dos dados.

O modelo de neurônio apresentado pela Figura 12 pode ser descrito matematicamente pelas equações abaixo. É importante mencionar que o uso dessas equações é aplicável quando o viés (b_j) é considerado como um dos sinais de entrada da rede (Haykin, 2009). Dessa forma, pressupõe-se que $x_0 = 1$ e $w_{0j} = b_j$.

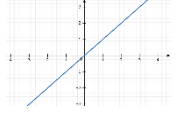
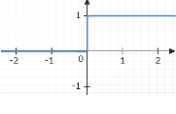


$$v_j = \sum_{i=0}^n w_{ij} x_i \quad (16)$$

$$y_j = \varphi(v_j) \quad (17)$$

A escolha da função de ativação depende da aplicação do modelo. As funções de ativação comumente utilizadas são funções não lineares como tangente hiperbólica e sigmoide, responsáveis por permitir que o modelo se ajuste a dados não lineares. Qualquer função não linear adotada permite que a rede neural aprenda funções muito mais complicadas do que um modelo linear (Müller & Guido, 2017). No entanto, a função linear geralmente é usada na camada de saída de uma rede quando a resposta do neurônio pode atingir qualquer valor, ou seja, não possui

intervalo inferior e superior. A Tabela 5 apresenta alguns tipos de funções de ativação.

Tabela 5 – Funções de ativação

Nome	Formulação matemática	Intervalo	Gráfico
Função linear	$\varphi(v_j) = v_j$	$(-\infty, +\infty)$	
Função degrau limiar	$\varphi(v_j) = \begin{cases} 0 & \text{para } v_j < 0 \\ 1 & \text{para } v_j \geq 0 \end{cases}$	$\{0,1\}$	
Função sigmoide	$\varphi(v_j) = \frac{1}{1 + e^{-v_j}}$	$(0,1)$	
Função tangente hiperbólica	$\varphi(v_j) = \tanh(v_j)$ $\varphi(v_j) = \frac{e^{(v_j)} - e^{-(v_j)}}{e^{(v_j)} + e^{-(v_j)}}$	$(-1,1)$	

2.4.2

Arquitetura e topologia

Os neurônios individuais possuem capacidade computacional limitada. Apesar disso, um conjunto de neurônios organizados em rede são capazes de resolver problemas de complexidade elevada. Assim, a arquitetura de uma rede neural está relacionada à maneira como os neurônios conectam-se entre si.

De forma geral, as redes neurais podem ser classificadas como *feedforward* ou recorrentes quanto à sua arquitetura. A rede *feedforward* se caracteriza pela organização dos neurônios em camadas, conectados por links (pesos), onde o fluxo de informações se dá em uma única direção, da camada de entrada para a camada de saída. Em redes recorrentes, há os dois tipos de conexões – *feedforward* e *feedbackward* – que permitem que a informação se propague em duas direções, ou seja, tanto dos neurônios de entrada para os de saída, quanto dos neurônios de saída para os de entrada.

A rede *feedforward* do tipo *Multilayer Perceptron* (MLP) destaca-se entre as arquiteturas de rede mais utilizadas, sendo o tipo de rede abordado neste trabalho. Essa rede contém uma camada de entrada, uma camada de saída e uma ou mais camadas escondidas, que se encontram entre as camadas de entrada e de saída. A camada de entrada não é composta de neurônios propriamente ditos, sendo

responsável apenas por distribuir os padrões para a camada seguinte. As camadas escondidas formam a estrutura central de processamento da rede neural e a camada de saída gera a resposta da rede. A Figura 13 mostra um exemplo de rede MLP.




Figura 13 – Estrutura de uma rede MLP

Na escolha do modelo de rede MLP a ser usado, um parâmetro importante a ser definido é o número de nós na camada escondida, assim como o número de camadas escondidas (Müller & Guido, 2017). O teorema da aproximação universal declara que uma única camada intermediária é suficiente para uma rede multicamada perceptron aproximar uniformemente qualquer função contínua, dado um conjunto de treinamento significativo para representar a função (Cybenko, 1989). No entanto, esse teorema não afirma que uma MLP com uma única camada é um método ótimo no sentido de tempo de aprendizado, facilidade de implementação ou generalização (Haykin, 2009).

2.4.3

Tratamento dos dados

Normalmente, a ordem de grandeza dos valores de entrada e saída são distintas e, por isso, é preciso adotar algum tipo de normalização dos dados antes de executar o treinamento da rede neural. Dessa maneira, estabelece-se a mesma escala para todos os valores, de forma que o valor de uma variável não se torne mais significativo do que outra no cálculo dos pesos da rede. As escalas definidas para a normalização das variáveis normalmente são intervalos entre 0 e 1, -1 e 1 ou escalas definidas a partir da média e do desvio padrão dos dados.

2.4.4

Algoritmo de treinamento

Uma das principais tarefas de uma rede neural é aprender a partir dos dados, de forma a ser capaz de interpolar e extrapolar os resultados. Essa etapa de aprendizagem consiste em um processo iterativo de ajuste dos parâmetros da rede

(pesos das conexões), denominado algoritmo de treinamento. Existem diversos algoritmos que diferem entre si pela maneira pela qual esse ajuste dos pesos é feito, sendo o de *Backpropagation* o mais conhecido e usado. As redes treinadas com esse algoritmo devem possuir arquitetura *feedforward* e funções de ativação continuamente diferenciáveis (Haykin, 2009).

O algoritmo de Backpropagation consiste em duas etapas. Na fase de propagação do sinal, os pesos da rede são fixados e o sinal da entrada é propagado através da rede, camada por camada, até chegar na camada de saída. A mudança dos pesos é restrita à função de ativação e saídas de cada neurônio da rede. Na fase de retropropagação, um sinal de erro é produzido ao comparar o resultado estimado pela rede com a resposta desejada. O resultado desse erro é propagado novamente camada a camada pela rede na direção contrária (para trás), realizando-se ajustes sucessivos nos pesos das camadas ocultas da rede por meio do algoritmo gradiente descendente (Figura 14).




Figura 14 – Direções de propagação do sinal funcional e do erro (adaptado de Haykin, 2009)

Este algoritmo calcula um gradiente (derivada parcial) do erro em relação aos pesos e o ajuste dos pesos é feito pela multiplicação desse gradiente com a taxa de aprendizado, que representa o tamanho do ajuste realizado entre uma iteração (época) e outra (Haykin, 2009). Este processo iterativo se repete até que o critério de parada seja atingido, normalmente estabelecido em função da minimização do erro que leva ao desempenho máximo da rede. O ajuste aplicado aos pesos na retropropagação pode ser expresso pela equação (18):

$$\Delta w_{ij} = -\eta \frac{\delta Erro}{\delta w_{ij}} \quad (18)$$

Cada peso w_{ij} do neurônio j é atualizado proporcionalmente ao negativo da derivada parcial do erro deste neurônio com relação ao peso, e η é a taxa de aprendizado que controla a taxa de atualização dos pesos. O sinal negativo é

responsável pela descida do gradiente no espaço de peso, ou seja, busca uma direção para a alteração de peso que reduz o valor do erro.

2.4.5

Critério de parada

Em geral, não é possível observar convergência no algoritmo de retropropagação e não há critérios bem definidos para interromper sua operação (Haykin, 2009). Há, no entanto, alguns critérios de parada que devem ser mencionados. O primeiro deles considera que o algoritmo de retropropagação converge quando a taxa absoluta de alteração no erro quadrático médio (função de custo) por época é suficientemente pequena. Essa taxa de alteração é considerada suficientemente pequena quando atinge entre 0.1% a 1% por época. Infelizmente, esse critério pode resultar no término prematuro do processo de aprendizagem (Haykin, 2009).

Outro critério de parada é baseado no desempenho de generalização da rede. Generalização se refere à capacidade da rede neural de prever resultados satisfatoriamente a partir de dados de entrada não utilizados no processo de treinamento ou aprendizagem. Assim, o processo de aprendizagem é interrompido quando se atinge uma generalização adequada ou ótima.

2.4.6

Avaliação e métricas de desempenho do modelo

Um dos cuidados que devem ser tomados no treinamento de uma rede neural é evitar ela emule os dados de treinamento, o chamado *overfitting*. Quando a rede memoriza os dados do treinamento, ela perde sua capacidade de generalização, não sendo capaz realizar um mapeamento não-linear correto de entrada-saída com dados diferentes dos usados no treinamento. Isso pode ocorrer devido a alguns fatores como a presença de atributos nos dados de entrada que inserem ruídos no modelo, pois tais atributos não contribuem de fato para o ajuste da função de aproximação da rede (Haykin, 2009). Outros fatores estão relacionados com o excesso de iterações ou épocas adotadas no processo de treinamento, assim como o excesso de neurônios ou camadas dependendo da complexidade do problema.

Para avaliar o desempenho da rede, separa-se o banco de dados disponível para a elaboração do modelo em um conjunto para treinamento e outro para teste

de forma aleatória. O conjunto de teste é usado no cálculo do erro entre os resultados reais e os estimados, para avaliar se o modelo de RNA apresenta uma boa generalização. O conjunto de treinamento pode, ainda, ser dividido em dois subconjuntos: treinamento e validação (Müller & Guido, 2017). Geralmente essa abordagem é utilizada para fazer a validação do modelo utilizando o procedimento de validação cruzada, na qual utiliza-se diferentes combinações de amostras para cada subconjunto de dados de forma a escolher o melhor conjunto de hiperparâmetros do modelo com base no seu desempenho (menor erro).

Na maioria dos casos, as saídas da rede não serão iguais ao valor desejado. O valor dessas diferenças é uma medida utilizada para avaliar o desempenho dos modelos. Há diversas métricas que permitem avaliar esse desempenho como a soma do erro quadrático (SSE), o erro quadrático médio (MSE), o erro percentual absoluto médio (MAPE) e o coeficiente de determinação (R^2). O coeficiente de determinação avalia a qualidade do ajuste do modelo, sendo uma medida intuitiva para avaliar modelos de regressão (Müller & Guido, 2017), enquanto as outras métricas citadas avaliam a precisão da resposta do modelo.

A soma do erro quadrático (SSE) é definida de acordo com a equação (19), onde n indica o número de amostras, Y_i é o valor real e \hat{Y}_i , o valor previsto. O erro quadrático médio (MSE) normaliza o SSE para o número n de amostras – equação (20). O erro percentual absoluto médio (MAPE) é uma medida com melhor sensibilidade na interpretação dos resultados, mais fácil de ser analisado, pois representa a distância percentual entre o valor previsto e o desejado – equação (21).

$$SSE = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (19)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \frac{1}{n} SSE \quad (20)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{|Y_i - \hat{Y}_i|}{Y_i} \quad (21)$$

O coeficiente de determinação, ou R^2 , é definido como o percentual da variabilidade da variável resposta que é explicada pelos regressores incluídos no modelo, ou seja, fornece uma medida de quão próximos os resultados observados estão da curva ajustada pelo modelo. O cálculo do R^2 é dado a partir da equação

(24), onde SS_{tot} é a soma total dos quadrados, SS_{exp} é a soma dos quadrados explicada e \bar{Y}_i é a média das observações.

$$SS_{tot} = \sum_{i=1}^n (Y_i - \bar{Y}_i)^2 \quad (22)$$

$$SS_{exp} = \sum_{i=1}^n (\hat{Y}_i - \bar{Y}_i)^2 \quad (23)$$

$$R^2 = \frac{SS_{exp}}{SS_{tot}} = 1 - \frac{SSE}{SS_{tot}} \quad (24)$$

O coeficiente de determinação é uma medida de fácil interpretação, porém deve ser usado com precaução, pois, para o mesmo modelo, o valor desse coeficiente aumenta com a adição de variáveis independentes, o que pode levar a uma análise equivocada a respeito da qualidade do ajuste do modelo. Assim, uma alternativa é usar o coeficiente de determinação ajustado (R_{adj}^2) que penaliza a inclusão de variáveis extras no modelo. O R_{adj}^2 é definido pela equação (25), onde n é o número de amostras e k é o número de variáveis independentes.

$$R_{adj}^2 = 1 - \left[\frac{(1 - R^2)(n - 1)}{n - k - 1} \right] \quad (25)$$

2.4.7

Modelos de RNA e de aprendizado de máquina na avaliação do dano em pontes de aço

Modelos de aprendizado de máquina possuem a capacidade de aprender a partir de padrões e, por isso, há uma vasta aplicação na solução de problemas da engenharia. No âmbito da avaliação da vida em fadiga de pontes, abordagens baseadas no aprendizado de máquina apresentaram avanços no sentido de reduzir o esforço computacional da análise. Estudos, descritos a seguir, também apontam a contribuição da utilização desses modelos na identificação do carregamento móvel a partir de dados de deformação, assim como na identificação de dano estrutural a partir de dados de vibração.

Na avaliação da vida em fadiga de pontes de aço, muitos estudos consideram as características locais do tráfego com a utilização de um modelo de carregamento estocástico obtido a partir de dados locais de pesagem em movimento de veículos (*weigh in motion* ou WIM). Essa abordagem normalmente é utilizada para simular

o espectro de tensão devido ao carregamento móvel na análise de confiabilidade de fadiga. No estudo realizado por Lu et al. (2017), utilizou-se uma abordagem que combina o método de *uniform design* (UD) com um modelo de aprendizado de máquina – o SVM (*support vector machine*) – para substituir a simulação em elementos finitos na avaliação da confiabilidade da fadiga de tabuleiros de ponte de aço sob o carregamento estocástico de caminhões. O modelo de SVM busca obter a resposta da variação de tensão equivalente de acordo com o peso dos eixos do veículo para cada tipo de veículo considerado no estudo. Nas análises numéricas realizadas em um tabuleiro de ponte de aço, os autores concluem que os parâmetros de tráfego (crescimento do volume de tráfego e do peso dos veículos) afetam significativamente o resultado do índice de confiabilidade e que a metodologia proposta pode fornecer embasamento teórico para o gerenciamento do tráfego, assim como para a manutenção da estrutura.

Utilizando a mesma abordagem de aprendizado de máquina, Zhu & Zhang (2018) investigaram a confiabilidade da fadiga em juntas soldadas críticas de uma ponte estaiada costeira sob cargas estocásticas de veículos, ventos e ondas. Os autores concluíram que cada carregamento contribui diferentemente para o acúmulo de dano por fadiga. De maneira semelhante aos estudos mencionados anteriormente, Lu et al. (2019) utilizam um modelo de rede neural para substituir a análise em elementos finitos de forma a obter os resultados de variação de tensão de acordo com o peso dos veículos considerados. O modelo é utilizado dentro de uma metodologia para análise de confiabilidade de fadiga de um tabuleiro de ponte de aço a partir de um modelo probabilístico de carregamento. Os autores relatam que a redução na confiabilidade de fadiga está associada principalmente à taxa de crescimento do peso dos veículos, enquanto o crescimento do volume de tráfego tem pequena contribuição na redução do índice de confiabilidade de fadiga.

Yan et al. (2019) utilizaram um modelo de rede neural e simulação Monte Carlo para investigar a confiabilidade de falha à fadiga de uma ponte mista (vigas de aço e tabuleiro de concreto) devido à sobrecarga de veículos. O modelo de rede neural foi utilizado para substituir a simulação em elementos finitos, que prediz o resultado da função de estado limite de fadiga (da análise de confiabilidade abordada). A partir da análise de diversos cenários, os autores concluem que quanto maior a proporção de veículos sobrecarregados de cinco eixos, mais rapidamente o índice de confiabilidade reduz, o que afeta a vida em fadiga de pontes de aço. Nos

estudos mencionados, apesar do tempo considerável necessário para a preparação dos dados para o treinamento dos modelos de aprendizado de máquina, o uso desses modelos é capaz estimar com precisão a probabilidade de falha em apenas alguns segundos, o que torna o processo de tomada de decisão mais rápido.

No estudo da identificação de dano em estruturas de pontes, dados a respeito do carregamento móvel nessas estruturas fornece dados relevantes para a análise estrutural em relação à fadiga. Dessa forma, Yang et al. (2016) aplicou o método de redes neurais com treinamento de retropropagação do erro para identificar esses dados de carregamento móvel. Dados de deformação obtidos sob diferentes carregamentos de veículos, distância entre eixos e velocidades foram utilizados como dados de entrada do modelo de rede neural para obter os parâmetros de carregamento – posição e peso dos eixos – tidos como parâmetros de saída da rede. A partir da análise numérica e experimental realizada, os autores concluem que a metodologia proposta é adequada para a identificação de parâmetros de carregamento e pode ser utilizada como uma forma simples e de baixo custo para um monitoramento à curto prazo.

Ainda no âmbito da identificação de dano estrutural, Finotti et al. (2019) comparam dois algoritmos de aprendizado de máquina – o SVM e redes neurais – para identificar mudanças na vibração estrutural usando os indicadores estatísticos, obtidos a partir da resposta dinâmica, como dados de entrada para esses algoritmos. O objetivo desses algoritmos é obter a classificação do nível de dano estrutural. A partir da aplicação da metodologia em dados de uma simulação numérica e em dados experimentais, os autores concluem que ambos os algoritmos apresentam bons resultados na predição da classificação da condição estrutural, sendo que o modelo de rede neural apresentou melhor desempenho na aplicação da metodologia nos dados experimentais.

Mehrjoo et al. (2008) apontam que o uso de inteligência artificial no campo de identificação do dano estrutural representa uma alternativa promissora para lidar com o cenário em que dados experimentais obtidos in situ são imprecisos e, muitas vezes, incompletos. A metodologia proposta pelos autores inclui o uso de um modelo de rede neural para prever a intensidade do dano de ligações em pontes de treliça utilizando as frequências naturais e modos de vibração como dados de entrada do modelo. A partir de duas análises numéricas realizadas em pontes de treliça, o estudo conclui que o uso da rede neural MLP é apropriado para a

identificação da localização e da severidade do dano nessas estruturas utilizando apenas os dados dos cinco primeiros modos de vibração.

De maneira semelhante a alguns estudos mencionados acima, o presente trabalho integra o uso de um modelo de rede neural com uma análise de confiabilidade estrutural para identificar o tempo de vida útil de pontes de aço. No entanto, o modelo de rede neural é treinado para ser capaz de prever a tensão equivalente de diferentes configurações de pontes de aço simplesmente apoiadas com a passagem de um único tipo de veículo – o veículo de fadiga da AASHTO. O modelo de confiabilidade estrutural utilizado introduz os danos por fadiga e corrosão conforme modelos de confiabilidade disponíveis na literatura. Assim, o protótipo de sistema proposto é capaz de realizar a estimativa do tempo de vida útil considerando esses mecanismos de deterioração para diversas geometrias de pontes de aço simplesmente apoiadas, desde que estejam dentro do intervalo de dimensões contempladas nessa pesquisa.

3

Método de pesquisa

O principal objetivo deste trabalho compreende o desenvolvimento de um protótipo de um sistema capaz de estimar o tempo de vida útil de pontes de vigas de aço simplesmente apoiadas sob diferentes cenários – com e sem manutenção – considerando os danos por fadiga e corrosão. Para isso, integrou-se métodos de análise estrutural, aprendizado de máquina e de confiabilidade estrutural no desenvolvimento do sistema.

O método dos elementos finitos (MEF) foi utilizado para obtenção dos resultados de tensão da viga da ponte de modo a completar um banco de dados elaborado com diferentes configurações de pontes que, por sua vez, foi utilizado para o treinamento e validação de um modelo de redes neurais. Assim, o modelo de RNA prediz a tensão equivalente com a passagem de um veículo de fadiga a partir das características geométricas e de material da ponte. Essa etapa permite o uso da ferramenta sem que haja a necessidade da elaboração e análise de um modelo em EF, facilitando o uso do sistema pelo usuário. Para a avaliação da segurança de pontes de aço, realizou-se uma análise de confiabilidade estrutural, que verifica a probabilidade de falha da estrutura ao longo do tempo a partir da consideração das incertezas do modelo de deterioração.

As informações fornecidas pela ferramenta desenvolvida, i.e., o tempo de vida útil com a presença e ausência de estratégias de manutenção, embora não suficientes, podem configurar como uma das etapas de um sistema de manutenção de pontes de aço. Assim, esta seção apresenta os métodos e resultados da modelagem em elementos finitos e da elaboração da rede neural, além do método utilizado para análise de confiabilidade estrutural e o fluxograma do funcionamento do sistema de manutenção proposto.

3.1

Modelagem de pontes em Elementos Finitos

O método dos elementos finitos é um método numérico para a solução aproximada de equações diferenciais parciais. Tal método é amplamente utilizado

na solução de problemas estruturais, especialmente em softwares computacionais de análise estrutural. Neste trabalho, o software de elementos finitos ABAQUS foi utilizado para realizar a análise das tensões nas vigas de pontes de aço devido ao carregamento móvel.

Pontes são estruturas que combinam vários componentes estruturais e a escolha dos elementos finitos utilizados é fundamental para a análise. Em estudo realizado por Chung & Sotelino (2005), os autores compararam os resultados da modelagem de pontes representados por diferentes modelos de elementos finitos e concluíram que o modelo de viga excêntrica é tão preciso quanto os outros modelos mais complexos estudados. A modelagem das vigas de aço que utiliza elementos de viga quadráticos é, portanto, capaz de representar adequadamente o comportamento a flexão de vigas, além de ser mais econômica. Por outro lado, modelos de viga que utilizam elementos de casca são capazes de modelar o comportamento local de uma viga de ponte, porém requerem um maior refinamento da malha para a convergência devido a incompatibilidade dos graus de liberdade de perfuração (*drilling*) da alma e de flexão das mesas.

Dessa forma, a escolha dos elementos finitos utilizados para a modelagem de um sistema estrutural deve levar em conta não só a precisão dos resultados do modelo, mas também o custo computacional associado à utilização desses elementos. Tal escolha depende do objetivo da aplicação da modelagem em EF. A seguir, apresenta-se o estudo realizado para a validação do modelo de elementos finitos desenvolvido para a análise da vida em fadiga de pontes de vigas de aço.

3.1.1

Validação do modelo – Ponte Nebraska

As técnicas de modelagem adotadas neste trabalho foram validadas a partir da comparação entre os resultados obtidos a partir da simulação de um modelo em elementos finitos e os resultados experimentais de um teste de carga realizado em uma ponte projetada e construída em escala real no laboratório da Universidade de Nebraska nos EUA. Os resultados desse teste experimental podem ser encontrados nos trabalhos de Azizinamini et al. (1995), Chung & Sotelino (2005) e Santos (2015). Além disso, realizou-se um estudo de convergência para se determinar a discretização necessária da malha de elementos finitos adotada neste trabalho.

3.1.1.1

Descrição da estrutura

A estrutura citada nesses estudos corresponde a uma ponte simplesmente apoiada com 21,40 m de comprimento e 7,90 m de largura. Sua superestrutura é formada por um tabuleiro de concreto com 19 cm de espessura apoiado por três vigas soldadas com 137 cm de altura, espaçadas a cada 3,04 metros. A seção transversal da ponte e das vigas pode ser observada na Figura 15, enquanto as propriedades do material são fornecidas na Tabela 6.




Figura 15 – (a) seção transversal da ponte; (b) detalhe da seção transversal da viga (adaptado de Santos, 2015)

Tabela 6 – Propriedades dos materiais (adaptado de Chung & Sotelino, 2005)

Propriedades dos materiais	Concreto		Aço			
	Tabuleiro	Parapeito	Mesa Superior	Mesa inferior (interna)	Mesa inferior (externa)	Alma
Módulo de Elasticidade (GPa)	-	-	193.7	180.6	191.0	200.6
Resistência à compressão (MPa)	43.0	41.8	-	-	-	-

O módulo de elasticidade do concreto do tabuleiro e do parapeito foi calculado de acordo com a fórmula estabelecida pela ACI 318 (2019) para o concreto de massa específica normal – equação (26). Assim, o módulo de elasticidade do concreto do tabuleiro e do parapeito calculado é de 31,03 GPa e 30,59 GPa, respectivamente.

$$E = 4732 \cdot \sqrt{f_{ck}} \text{ (MPa)} \quad (26)$$

3.1.1.2 Prova de carga

Nos testes de carga realizados pela universidade de Nebraska, diversas configurações de carregamento e geometria da ponte foram testadas. Durante cada teste, simulou-se a carga aplicada nas rodas dianteiras e traseiras, com um ou dois caminhões pesando aproximadamente 800 kN cada – 178 kN para os eixos intermediários e traseiros e 44,48 kN para os eixos dianteiros. Esse peso corresponde a 2,5 vezes o peso do caminhão HS-20 da AASHTO (Azizinamini et al., 1995). Para a validação do modelo, adotou-se o caso da simulação de dois caminhões posicionados lado a lado, um em cada faixa da ponte, sem a presença de contraventamento. O posicionamento dos caminhões na ponte, assim como a distância entre os eixos dianteiros, centrais e traseiros dos caminhões podem ser verificados na Figura 16.




Figura 16 – Setup da prova de carga (adaptado de Azizinamini et al., 1995)

3.1.1.3 Modelo de elementos finitos

Neste trabalho, foram utilizados elementos de viga de três nós (B32) para a modelagem do guarda corpo, e elementos retangulares de 8 nós de casca fina com integração reduzida (S8R) para a modelagem do tabuleiro e das vigas de aço. A escolha de elementos de casca para a representação das vigas de aço foi motivada pelo objetivo de se obter a tensão na interface entre a alma e a mesa inferior das

vigas de aço com maior precisão, pois é onde se localiza a solda desses elementos – detalhe estrutural considerado na análise da vida em fadiga posteriormente.

O carregamento dos caminhões, descrito na seção anterior, foi representado pela aplicação de cargas concentradas no tabuleiro de concreto na posição central das rodas. Esta aproximação das cargas como sendo concentradas é adequada uma vez que o local da resposta desejada se encontra longe do local de aplicação das cargas. Na modelagem das vigas, o posicionamento das mesas superior e inferior em relação à alma da viga foi ajustado de forma que não haja sobreposição de material. Para isso, inseriu-se uma distância “offset” de deslocamento para os elementos de casca das mesas.

A ação compósita entre o tabuleiro de concreto e as vigas de aço foram modeladas por ligações rígidas através de elementos “*tie constraints*” disponíveis no ABAQUS. Tais elementos unem duas regiões separadas de forma que não haja movimento relativo entre elas, sendo possível especificar uma distância absoluta entre a região principal (mestre) e a escrava. Essa distância refere-se, nesse caso, à excentricidade entre o tabuleiro de concreto e a mesa superior da viga. Dessa forma, foram aplicadas restrições cinemáticas para todos os deslocamentos e rotações entre os nós das vigas e do tabuleiro através das ligações rígidas. A ligação entre o guarda-corpo e tabuleiro também foi estabelecida a partir de ligações rígidas do tipo “*tie*”.

Como o objetivo do estudo é a análise da superestrutura de pontes, não foi necessário modelar os detalhes da mesoestrutura (aparelhos de apoio) e subestrutura (pilares e fundações). Assim, apenas as condições de contorno foram atribuídas na região dos apoios localizados abaixo das vigas de aço nas extremidades do vão. Dessa forma, os deslocamentos verticais e transversais foram restringidos nos apoios, as rotações em todas as direções foram permitidas e os deslocamentos longitudinais foram restringidos apenas em um dos lados da estrutura de forma a simular uma estrutura simplesmente apoiada.

A Figura 17 mostra o modelo em elementos finitos, a discretização da malha para a qual os resultados convergiram com uma diferença de apenas 0,8% em relação a um refinamento maior. A figura também mostra o posicionamento do carregamento e das condições de contorno da ponte simulada.




Figura 17 – Modelo em EF da ponte da Universidade de Nebraska

3.1.1.4

Considerações sobre os elementos secundários

Na maioria dos trabalhos encontrados na literatura, os elementos secundários – como transversinas e guarda-corpo – não são considerados na modelagem de pontes de viga. Segundo Akinci et al. (2008), a modelagem dos guarda-corpos em uma análise estrutural pode contribuir significativamente para a rigidez de uma ponte. Além disso, dependendo da rigidez das vigas e do parapeito, os fatores de distribuição de carga da viga podem diminuir até 30% se os caminhões estiverem posicionados próximos aos parapeitos.

Segundo estudos de Eamon & Nowak (2004), a consideração das transversinas causa uma redução de até 13% (média de 4%) nos momentos máximos das longarinas, enquanto a consideração do guarda corpo causa uma redução de até 32% (média de 10%) nos momentos máximos das longarinas. Em estudo semelhante, Chung et al., (2006) observam uma redução de até 11% nos fatores de distribuição de carga das longarinas ao considerarem a modelagem das transversinas, enquanto uma redução de até 25% foi observada ao considerarem a modelagem do guarda corpo.

De acordo com esses estudos, a modelagem dos elementos secundários influencia os resultados dos modelos de EF diferentemente, dependendo do elemento considerado. Desse modo, optou-se por modelar apenas o guarda-corpo no modelo de elementos finitos que será utilizado nas análises de tensão, pois segundo testes realizados, a ausência desse componente causa diferenças

significativas nos resultados. Além disso, essa abordagem foi a mesma utilizada no estudo de Chung & Sotelino (2005).

3.1.1.5 Resultados

A comparação entre os resultados obtidos pelo modelo de elementos finitos desenvolvido neste trabalho e os resultados do teste de carga são apresentados na Tabela 7. Percebe-se que a diferença para o deslocamento da viga interior no meio do vão foi de apenas 1,9%. A maior diferença entre os resultados foi para o deslocamento no meio do vão para a viga externa, porém ainda dentro de um limite aceitável – menor que 10%. Dessa forma, conclui-se que o modelo é capaz de representar adequadamente o comportamento de uma ponte mista. No estudo de convergência, percebeu-se que uma malha de 25 cm fornece resultados satisfatórios para uma tolerância de menos de 5%.

Tabela 7 – Resultados de validação do modelo

Resultados do Experimento/ Modelo	Deslocamento (mm)			
	Meio do vão		1/4 do vão	
	viga interna	viga externa	viga interna	viga externa
Azizinamini, Kathol e Beacham (1995)	19,0	13,95	13,1	9,78
Modelo de EF	19,37	15,0	12,86	10,45
diferença relativa	1,9%	7,5%	1,8%	6,9%

3.2 Configurações de pontes da base de dados

Com a técnica de modelagem escolhida para obter os resultados de tensão de vigas de ponte de aço, buscou-se estabelecer as possíveis configurações de pontes de aço para a formação de um banco de dados. Para isso, foram escolhidos parâmetros físicos e geométricos mais comuns de pontes de aço de acordo com recomendações da norma americana (AASHTO, 2012) e de departamentos de transporte dos Estados Unidos. Esses parâmetros são listados a seguir:

- Parâmetros de geometria:
 - Comprimento do vão
 - Número de faixas de rolamento
 - Largura da faixa de rolamento

- Largura do tabuleiro
- Espaçamento entre vigas
- Largura do balanço
- Espessura do tabuleiro
- Dimensões da viga de aço
- Parâmetros de material:
 - Módulo de elasticidade do concreto
 - Módulo de elasticidade do aço.

No presente trabalho, a avaliação do tempo de vida de uma estrutura devido às ações dos fenômenos de fadiga e corrosão foca em estruturas de ponte de um único vão. Estabeleceu-se então que as análises seriam realizadas para vãos de 15, 20, 30, 40, 50 e 60 metros. Para a definição da largura do tabuleiro, é necessário levar em consideração diversos fatores como a existência ou não de passeios e acostamentos, largura da defesa e o número de faixas de rolamento. Assim, definiu-se que a presença de passeios e acostamentos seria desconsiderada. Em relação ao número de faixas, adotaram-se pontes com um número de 2, 4 e 6 faixas de rolamento com 3,6 metros de largura para cada faixa. Além disso, consideraram-se pontes que apresentam barreiras de concreto contínuas (tipo New Jersey) com 0,4 metros de largura e 0,81 metros de altura presentes apenas nas extremidades da seção transversal do tabuleiro.

O espaçamento entre vigas está relacionado com o número de vigas, a largura do balanço, e a largura e espessura do tabuleiro adotados pelo projetista, embora não haja uma recomendação específica da norma americana para o pré-dimensionamento desses parâmetros. Em exemplos de dimensionamentos de ponte de viga de aço, sugere-se que a largura do balanço pode variar de 29%, 35% a 50% do espaçamento entre vigas (Baker, 2003; Grubb et al., 2015). Consideraram-se então dois cenários para a largura do balanço: de 0,3 e 0,5 vezes o espaçamento entre vigas – definido como a relação balanço/ espaçamento. O espaçamento entre vigas foi definido a partir do número de vigas de ponte e da relação balanço/espaçamento. Assim, adotou-se um número entre 3 a 12 vigas, de forma que o espaçamento estivesse aproximadamente dentro do intervalo de 1,5 a 4,5 metros de acordo com a largura da ponte. Para a espessura do tabuleiro, adotaram-se três valores – 150, 200 e 250 mm. Os valores ou intervalos de valores de cada parâmetro de geometria do tabuleiro são expostos na tabela Tabela 8.

Tabela 8 – Parâmetros de geometria (tabuleiro)

Parâmetros de geometria	Valores/ intervalos de valores
vão (m)	15; 20; 30; 40; 50; 60
número de faixas	2; 4; 6
largura da faixa (m)	3,6
largura da defesa (m)	0,4
largura (m)	8; 15,4; 22,6
número de vigas	3 a 12
balanço (m)	0,4 – 1,9
espaçamento (m)	1,6 – 4,3
espessura tabuleiro (mm)	150; 200; 250

De acordo com alguns testes em modelos de EF, verificou-se que a variação nos valores do módulo de elasticidade para o concreto não causa grandes diferenças nos resultados, por isso, utilizou-se apenas dois valores. Já a variação dessa propriedade para o aço, que varia entre 190 a 210 GPa, não causa uma diferença significativa nos resultados de tensão. Dessa forma, o módulo de elasticidade E do concreto foi calculado de forma aproximada considerando-se um f_{ck} de 25 e 50 MPa, de acordo com a ACI 318 (2019). Já para o módulo de elasticidade do aço, adotou-se o valor de 200 GPa (Tabela 9).

Tabela 9 – Parâmetros de material

Material	Valores
Aço	200 GPa
Concreto	25 e 35 GPa

Os parâmetros da tabela Tabela 8 e Tabela 9 foram combinados de maneira que fosse possível formar 204 configurações de pontes diferentes para cada vão. Para cada configuração de ponte definida a partir da geometria do tabuleiro e dos materiais, foram então definidas cinco sessões transversais de viga de aço diferentes. No total, foram obtidas 6120 configurações diferentes de pontes. A definição das dimensões dos componentes das vigas de aço é descrita a seguir.

A norma americana de projeto de pontes (AASHTO, 2012) relata que a altura da viga de aço deve ser maior do que a razão do vão/30. Dessa forma, estabeleceu-se que a altura da alma, que contribui majoritariamente para a altura da viga, teria uma variação de valores entre a razão do vão/20 e vão/30. As outras dimensões da viga foram definidas de forma que atendessem as recomendações dos limites de proporcionalidade para vigas de aço, expressos pelas equações (27) a (32).

$$\frac{h_w}{t_w} \leq 150 \text{ (alma sem enrijecedores transversais)} \quad (27)$$

$$b_f \geq \frac{h_w}{6} \quad (28)$$

$$b_{fc} \geq \frac{L}{85} \quad (29)$$

$$\frac{b_f}{2t_f} \leq 12 \quad (30)$$

$$0.1 \leq \frac{I_{yc}}{I_{yt}} \leq 10 \quad (31)$$

$$t_f \geq 1.1 t_w \quad (32)$$

Onde h_w é a altura da alma, t_w é a espessura da alma, b_f é a largura das mesas, b_{fc} é a largura da mesa de compressão, t_f é a espessura das mesas, I_{yc} é o momento de inércia da mesa de compressão (superior) e I_{yt} é o momento de inércia da mesa de tração (inferior).

Com base nas relações estabelecidas por esses limites, definiram-se as demais dimensões da viga. Para a espessura alma, definiu-se uma variação entre $h_w/50$ e $h_w/150$. Para a largura da mesa superior, b_{fc} , estabeleceu uma variação entre $h_w/2,5$ e $h_w/6$. Já para a espessura da mesa superior, t_{fc} , adotaram-se valores de 1,1 a 2,1 vezes t_w . A partir de alguns exemplos de projetos, verificou-se que normalmente as dimensões da mesa inferior são maiores do que as dimensões da mesa superior. Isso se deve ao fato de que a mesa inferior contribui de maneira significativa no momento de inércia da viga e, assim, na capacidade de carga do elemento. Assim, definiu-se que as dimensões da mesa inferior – largura, altura ou ambas – seriam maiores em relação à mesa superior. Para a largura da mesa inferior, b_{ft} , definiu-se um intervalo de valores entre b_{fc} e 1,5 vezes b_{fc} . Já para a espessura da mesa inferior, t_{ft} , adotou-se um intervalo de valores entre t_{fc} e 2,1 vezes t_{fc} .

As configurações de pontes formadas a partir das dimensões da viga (Tabela 10) combinadas com os parâmetros das tabelas Tabela 8 e Tabela 9 foram verificadas de acordo com os critérios de limites de proporcionalidade e os critérios de estado limite último e de serviço para as vigas internas em relação ao momento fletor – esforço que normalmente governa o dimensionamento de pontes de aço

simplesmente apoiadas (Czarnecki, 2006; Deng et al., 2019; González et al., 2011). Esses critérios de verificação são adotados a partir das recomendações da AASHTO (2012).

Tabela 10 – Parâmetros de geometria – dimensões da viga de aço

Parâmetros de geometria da viga	Valores/ intervalos de valores
Altura da alma (mm), h_w	$V_{\text{ão}}/20 - v_{\text{ão}}/30$
Espessura da alma (mm), t_w	$h_w/50 - h_w/150$
Largura da mesa superior (mm), b_{fc}	$h_w/2,5 - h_w/6$
Espessura da mesa superior (mm), t_{fc}	$1,1t_w - 2,1t_w$
Largura da mesa inferior (mm), b_{ft}	$b_{fc} - 1,5b_{fc}$
Espessura da mesa inferior (mm), t_{ft}	$t_{fc} - 2,1t_{fc}$

3.2.1

Modelos em EF das pontes da base de dados

A falha por fadiga de um elemento estrutural está diretamente relacionada com a faixa de variação de tensão e o número de ciclos que determinado detalhe estrutural do elemento é submetido, conforme exposto na seção 2.1. Assim, o objetivo da análise do modelo em EF é a extração da faixa de variação de tensão do ponto de interesse no elemento estudado e a contagem do número de ciclos. O ponto de interesse considerado neste trabalho corresponde à solda entre a alma e a mesa inferior das vigas de aço. Logo, os resultados de tensão dos modelos foram extraídos na interface entre esses dois elementos da viga. As 6120 configurações de pontes foram modeladas pelo *software ABAQUS* a partir de um código desenvolvido em *Python* para criar os modelos e extrair os resultados do programa.

3.2.1.1

Modelagem

Cada modelo consiste em três tipos de elementos, assim como no modelo de validação. Elementos de casca de oito nós (S8R) representam as vigas e tabuleiro, elementos de viga de três nós (B32) representam a barreira de concreto, e os elementos de ligação rígida ('tie constraint') representam a ação compósita viga-tabuleiro e tabuleiro-barreira. Assim como no modelo de validação, decidiu-se desconsiderar a presença de transversinas. Quanto ao tamanho da malha de elementos finitos adotada, utilizou-se uma com elementos de tamanho de 0,25 m (encontrada no estudo de convergência) para análise de todos os modelos.

De acordo com a base de dados criada, todas as configurações de pontes consideradas neste trabalho apresentam uma barreira de concreto do tipo New Jersey. As dimensões da barreira são mostradas na Figura 18(a). No modelo de EF, esse elemento foi representado por um elemento de viga de três nós, assim como no modelo validado anteriormente. No entanto, modificou-se a seção transversal da barreira para um trapézio isósceles com mesma largura, altura e distância do centro de gravidade em y em relação à barreira New Jersey considerada. A ação compósita entre a barreira e o tabuleiro também foi modelada por ligações rígidas.




Figura 18 – Dimensões (em mm) da barreira do tipo New Jersey (a) considerada na base de dados e (b) representada no modelo em EF

3.2.1.2 Carregamento

A faixa de tensão em um ponto de interesse é obtida a partir do registro das tensões com a passagem do carregamento móvel. O ponto de interesse considerado neste trabalho é a solda entre a alma e a mesa inferior das vigas de aço localizada no meio do vão, detalhe estrutural da categoria B (ver Figura 4) de acordo com a classificação de detalhes na AASHTO (2012). Neste trabalho, adotou-se as recomendações normativas da AASHTO para a verificação da fadiga, em que a faixa de tensão é obtida a partir da passagem de um veículo de fadiga pela ponte, representado na Figura 6 (capítulo 2).

O veículo de fadiga foi ajustado de forma que seu carregamento total correspondesse a um carregamento unitário. Assim, a tensão resultante para análise final da fadiga é equivalente ao produto da tensão unitária obtida no modelo pela carga total do caminhão. Realizou-se então uma análise estática para extrair os resultados de tensão no detalhe estrutural. Cada passagem de veículo nas configurações de pontes analisadas representa um ciclo de tensão.

Como as estruturas da base de dados são pontes simplesmente apoiadas, o valor da faixa de tensão no detalhe estrutural devido ao carregamento móvel pode ser aproximado pelo valor da tensão máxima que ocorre no meio do vão das vigas. Assim, o resultado de tensão obtido do modelo para análise de fadiga corresponde à máxima tensão do detalhe estrutural no meio do vão dentre todas as vigas que constituem a estrutura.

O posicionamento longitudinal dos eixos do veículo foi feito a partir do estudo de linhas de influência, conforme ilustrado na Figura 19. Quanto ao posicionamento transversal do veículo de fadiga, definiu-se a posição do caminhão na faixa de rolamento externa, com espaçamento de 0,6 metros do meio-fio ou guarda corpo (AASHTO, 2012), conforme Figura 20. Tal posição não é a mais desfavorável para todas as configurações de pontes, pois dependendo do espaçamento entre vigas, a tensão máxima pode ocorrer com o caminhão centralizado transversalmente. No entanto, segundo Grubb et al. (2015), a faixa externa é normalmente a faixa de tráfego pela qual passa a maior parte dos caminhões que atravessam uma ponte. Por isso, optou-se por adotar essa posição para o veículo de fadiga para todas as pontes.




Figura 19 – Posicionamento longitudinal do veículo a partir da linha de influência de uma estrutura simplesmente apoiada de 20 metros




Figura 20 – Posicionamento transversal do veículo

3.3

Elaboração do modelo de redes neurais

O modelo de RNA foi utilizado neste trabalho para fazer a previsão da tensão unitária máxima em vigas de pontes de aço simplesmente apoiadas. Como a resposta do modelo é uma variável quantitativa, esse problema é classificado como um aprendizado supervisionado de regressão. Assim, rede neural escolhida para modelar o problema é a *multilayer perceptron* (MLP), juntamente com o algoritmo de treinamento de *back-propagation*. A seguir, apresenta-se o procedimento realizado para a obtenção desse modelo preditivo.

3.3.1

Aquisição e análise dos dados

A implementação de um modelo de RNA como estimador de funções necessita de uma quantidade de dados que representem bem o problema. As características que podem influenciar na tensão são os atributos geométricos de cada parte da estrutura e os atributos dos materiais utilizados.

Tabela 11 – Atributos da RNA

Categoria	Atributos
Características gerais:	- Comprimento do vão ($L_{vão}$)
	- Número de faixas de rolamento (n_{faixa})
	- Largura do tabuleiro (W_{tab})
	- Número de vigas (n_{vigas})
	- Espaçamento entre vigas (E_{viga})
	- Largura do balanço ($W_{balanço}$)
	- Espessura do tabuleiro (t_{tab})
	- Módulo de elasticidade do concreto (E_c)
Dimensões das vigas:	- Altura da alma (h_w)
	- Espessura da alma (t_w)
	- Largura da mesa superior (b_{fc})
	- Espessura da mesa superior, (t_{fc})
	- Largura da mesa inferior (b_{ft})
	- Espessura da mesa inferior (t_{ft})
Propriedades da seção:	- Área (A_{viga})
	- Centro de gravidade (C_g)
	- Momento de inércia (I_x)
	- Módulo de resistência superior (S_{sup})
	- Módulo de resistência inferior (S_{inf})

Dessa forma, os preditores de tensão do modelo de rede neural são obtidos a partir do procedimento exposto na seção 3.2, que trata da elaboração do banco de

dados. Além dos dados estimados, algumas propriedades da seção das vigas de aço foram calculadas a partir de suas dimensões com o intuito de testar se esses atributos também influenciam na tensão. A Tabela 11 mostra a relação dos atributos considerados.

Os valores de tensão unitária máxima para cada uma das 6120 configurações de pontes são obtidos a partir da modelagem dessas estruturas em um programa de EF – procedimento descrito em 3.2.1. A distribuição dos valores de tensão é exposta na Figura 21. Percebe-se que a distribuição dos valores de tensão apresenta, aproximadamente, a forma de uma distribuição normal (com baixa assimetria), o que pode facilitar a aproximação da função da rede.




Figura 21 – Histograma dos valores de tensão unitária máxima

3.3.2 Seleção dos atributos

A base de dados final adotada para o modelo preditivo conta com 19 atributos no total de acordo com a Tabela 11. Em um modelo de aprendizado de máquina, no entanto, nem todos os preditores presentes em um conjunto de dados colaboram para a precisão dos resultados. Alguns atributos podem, inclusive, piorar essa precisão. Por esse motivo, a seleção das variáveis de entrada contribui para o aumento de generalização do modelo, além de diminuir o tempo necessário para o treinamento da rede.

Uma das formas de realizar essa seleção é a partir da análise do coeficiente de correlação entre as variáveis de entrada do modelo, que representa a direção e o grau de associação entre duas variáveis. Quando duas variáveis apresentam um alto coeficiente de correlação, tais variáveis apresentam quase o mesmo efeito na variável resposta, não sendo necessário a inclusão de ambas no modelo preditivo.

Neste trabalho, a associação entre variáveis foi analisada com o coeficiente de correlação de Spearman (Spearman, 1904), uma medida de correlação não paramétrica avaliada no intervalo de valores entre -1 e 1. O coeficiente de Spearman é capaz de verificar a existência de relações tanto lineares como não lineares, pois não exige a suposição de que a relação entre as variáveis seja linear.

A partir da matriz de correlação com coeficientes de Spearman, verificou-se as variáveis que apresentavam um alto coeficiente de correlação, neste trabalho definido entre os valores 0.7 e 1, de forma a identificar as possíveis variáveis redundantes para o modelo. Além da análise do coeficiente de correlação, o processo de seleção de variáveis também levou em consideração o conhecimento técnico a respeito do problema. Assim, em algumas situações, apesar da presença de um alto coeficiente de correlação entre duas variáveis, ambas variáveis podem ser consideradas no modelo caso sejam relevantes na definição do problema. Com esses critérios, selecionou-se alguns subconjuntos de atributos, dentro do mesmo conjunto de dados das 6120 pontes, utilizados para o treinamento do modelo e escolha da melhor configuração de rede neural. Os resultados dessa seleção são apresentados na seção 3.3.7.

3.3.3 Configuração dos experimentos

A estrutura e o comportamento do algoritmo de treinamento das redes neurais MLP são determinados por hiper-parâmetros, definidos antes do treinamento do modelo. Cada especificação de valores dos hiper-parâmetros define um modelo diferente de rede neural, que apresenta um desempenho de acordo com o conjunto de atributos selecionados.

A implementação da rede neural foi feita a partir da biblioteca *scikit-learn* (versão 0.22) do *Python* (versão 3.7), com o algoritmo *MLPRegressor* (*'Multilayer perceptron regressor'*), que utiliza a retropropagação do erro para o treinamento da rede. Nesse algoritmo, há uma definição de referência dos hiper-parâmetros do modelo que, em algoritmos de aprendizado de máquina, normalmente representa o modelo com melhor desempenho para a solução de muitos problemas. É possível, no entanto, testar outros hiper-parâmetros no modelo a fim de ajustá-lo e melhorar seu desempenho.

Dessa forma, definiu-se os experimentos baseados na permutação dos valores de quatro hiper-parâmetros: algoritmo de solução de minimização do erro (*solver*), número de neurônios, função de ativação e a consideração ou não de parada antecipada. O número de camadas internas também influencia no desempenho da rede neural. No entanto, adotou-se apenas uma camada interna para todos os modelos já que segundo o teorema da aproximação universal, uma rede MLP de apenas uma camada é capaz de aproximar qualquer função não linear.

Para o algoritmo de solução, os experimentos foram feitos com os três métodos disponíveis no algoritmo MLPRegressor: gradiente descendente estocástico (em inglês, *Stochastic Gradient Descent* – SGD), Adam e L-bfgs. O gradiente descendente estocástico é um método iterativo para otimizar uma função objetivo. No caso da rede neural, esse método atualiza os parâmetros do modelo usando o gradiente da função de perda em relação ao parâmetro que precisa de adaptação. O Adam é semelhante ao SGD no sentido de ser um otimizador estocástico e apresenta ótimo desempenho para a maioria dos problemas mesmo com os parâmetros padrões do algoritmo (Müller & Guido, 2017). L-bfgs é um otimizador mais robusto que aproxima o inverso da a matriz Hessiana (representa a derivada parcial de segunda ordem de uma função) para realizar atualizações de parâmetros.

A seleção do número de neurônios para a realização dos experimentos foi baseada no número de atributos de cada conjunto de dados, definido como uma porcentagem do número total de atributos. As funções de ativação da camada interna foram variadas entre a função sigmoide e tangente hiperbólica. Na camada de saída, o algoritmo utiliza uma função de ativação linear, pois trata-se de um problema de regressão que deve ser capaz de prever qualquer valor contínuo. A Tabela 12 mostra um resumo dos hiper-parâmetros variados na busca pelo modelo de RNA que seja capaz de prever a tensão máxima com maior precisão.

Tabela 12 – Experimentos

Solver	Número de neurônios (proporção do nº de atributos)	Função de ativação	Parada Antecipada
• SGD	• 50%	• ‘tanh’ (tangente hiperbólica)	• Sim
• Adam	• 75%		• Não
• L-bfgs	• 100%	• ‘Logistic’ (sigmoide logística)	
	• 125%		
	• 150%		

3.3.4 Estratégia para escolha do modelo

Após a definição dos conjuntos de dados com diferentes atributos e das configurações dos experimentos a serem conduzidos, cada conjunto de dados foi separado em seu respectivo conjunto de treinamento e teste. Essa separação foi feita alocando-se 20% do total de amostras para o conjunto de teste e 80% para o conjunto de treinamento de forma aleatória.

Na busca pelo melhor modelo de rede neural para um determinado conjunto de dados, utilizou-se a técnica estatística de validação cruzada. Tal técnica tem o objetivo de avaliar a capacidade preditiva de um modelo treinado a partir de determinado conjunto de dados. Uma das variações dessa técnica de validação cruzada mais comuns é denominada de método *k-fold*, que consiste em dividir o conjunto de dados de treinamento do modelo em k subconjuntos. O modelo foi então treinado com $k - 1$ subconjuntos e validado com um único subconjunto. Tal procedimento foi repetido k vezes, variando-se o subconjunto destinado à validação da rede a cada repetição (tentativa).

Os subconjuntos de treinamento e de validação de cada iteração foram então normalizados em relação aos dados utilizados para treinar o modelo. A normalização das variáveis evita que a sua ordem de grandeza influencie no ajuste dos pesos da rede neural, conforme explicado na seção 2.4. Logo, todos os dados de entrada e saída foram normalizados no intervalo de 0 e 1 de acordo com a equação (33), onde x_n é o valor normalizado, x é o valor do dado real e os índices max e min são seus valores máximos e mínimos, respectivamente.

$$x_n = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (33)$$

O desempenho do modelo de rede neural foi avaliado a partir das métricas de erro para modelos de regressão, apresentadas na seção 2.5.4. No método *k-fold* de validação cruzada, as métricas de erro do modelo são calculadas em cada k repetição para cada configuração de rede. Para avaliar a capacidade de generalização do modelo, analisou-se o desempenho médio de cada configuração, obtido a partir de média dos erros de validação. Neste trabalho, definiu-se um número de cinco repetições para realizar a validação cruzada do modelo. Tal escolha foi baseada no esforço computacional que aumenta consideravelmente com o aumento de k subconjuntos.

Dentre as métricas de erro que avaliam o desempenho de uma rede neural, adotou-se como critério de escolha do melhor modelo aquele que apresentou o menor erro quadrático médio (MSE). O erro percentual absoluto médio (MAPE) e o coeficiente de determinação ajustado (R_{adj}^2), também foram calculados para complementar a análise.

3.3.5 Critérios de parada

Um dos critérios utilizados para interromper o treinamento da rede foi o método de parada antecipada. Nesse procedimento, compara-se o erro dos dados de treinamento com o erro dos dados de validação a fim de se determinar o momento de encerrar o treinamento da rede – ponto de parada antecipada (Figura 22).




Figura 22 – Ilustração da regra de parada antecipada baseada na técnica de validação cruzada (adaptado de Haykin, 2009)

No início do treinamento, erro de treinamento e validação tendem a reduzir, indicando uma boa evolução no aprendizado da rede. Após determinado momento (número de épocas), no entanto, o erro de validação passa a aumentar. Isso indica que o modelo preditivo pode estar emulando os dados de treino, perdendo a capacidade de realizar previsões satisfatórias de dados não vistos representados pelos dados de validação. Dessa forma, o ponto de parada antecipada corresponde ao momento em que o erro de validação começa a aumentar. Tal critério é válido apenas quando o algoritmo de solução utilizado é o gradiente descendente estocástico ou o Adam.

Outro critério de parada utilizado corresponde ao momento em que a função de custo (minimização do erro) do treinamento não apresenta uma redução significativa. Neste trabalho, considerou-se esse critério no caso de não haver

parada antecipada, quando o erro do treinamento não atingir um valor mínimo de 10^{-4} em 10 épocas consecutivas.

3.3.6

Definição do modelo final

Após escolha da configuração de rede neural associada ao conjunto de atributos que apresentou melhor desempenho, preparou-se o modelo escolhido para realizar as previsões a partir de novos dados, representados pelos dados de teste nesse contexto. Os dados de treinamento, constituídos por todos os k subconjuntos, foram então normalizados e utilizados no treinamento do modelo para calcular os parâmetros da RNA final – valores dos pesos dos coeficientes e viés.

Com isso, avaliou-se o desempenho do modelo final nos dados de teste a fim de verificar a qualidade da predição. O modelo de redes neurais obtido (Figura 23) relaciona a tensão máxima de vigas de pontes de aço simplesmente apoiadas com os valores dos atributos presentes no conjunto de dados escolhido por meio das equações abaixo.

$$e_j^{[1]} = X_i^{[0]} W_{ij}^{[1]} + b_j^{[1]} \quad (34)$$

$$h_j^{[1]} = \varphi^{[1]}(e_j^{[1]}) \quad (35)$$

$$\hat{y}_k^{[2]} = \varphi^{[2]}(h_j^{[1]} W_{jk}^{[2]} + b_k^{[2]}) \quad (36)$$

Onde:

- $W_{ij}^{[L]}$ é a matriz dos pesos da camada L com dimensão $(n^{[L]}, n^{[L-1]})$, onde n é o número de neurônios da camada correspondente, e relaciona o neurônio i da camada $[L - 1]$ com o neurônio j da camada $[L]$;

- $b_j^{[L]}$ é o vetor de viés da camada L com dimensão $(1, n^{[L]})$ associado ao neurônio j da camada $[L]$;

- $X_i^{[0]}$ é a matriz da camada zero (de entrada) com dimensão $(1, n_x)$, onde n_x corresponde ao o número de atributos;

- $\varphi^{[1]}$ é a função de ativação da primeira camada (camada escondida);

- $\varphi^{[2]}$ é a função de ativação da segunda camada (de saída);

- $e_j^{[1]}$ é o vetor do bloco de soma da primeira camada com dimensão $(1, n^{[1]})$, que contém a combinação linear de pesos e sinais de entrada e os valores de viés da primeira camada;
- $h_j^{[1]}$ é o vetor dos neurônios da primeira camada (camada escondida) com dimensão $(1, n^{[1]})$;
- $\hat{y}_k^{[2]}$ é o vetor da tensão unitária máxima prevista com valor normalizado de dimensão $(1, 1)$, que corresponde à segunda camada da RNA (de saída).

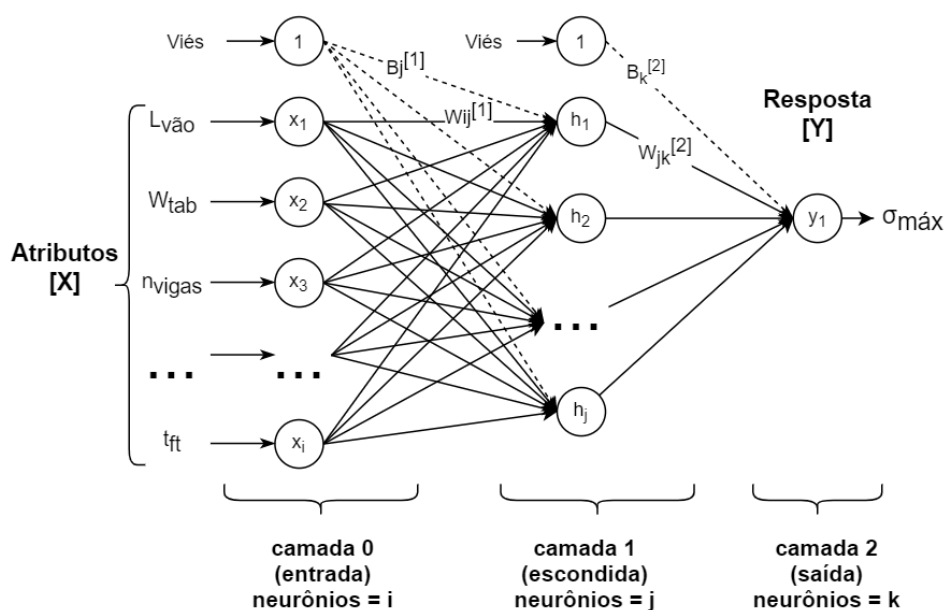


Figura 23 – Representação esquemática da rede neural artificial

3.3.7 Resultados

3.3.7.1 Seleção dos dados de entrada

Na matriz de correlação dos atributos (Figura 24), os coeficientes em vermelho mostram alta correlação entre atributos. Por exemplo, percebe-se uma alta correlação (valores do coeficiente entre 0.7 e 1.0) entre a largura do tabuleiro e o número de faixas, entre o vão da ponte com as dimensões e com as propriedades da seção da viga, assim como entre as dimensões e as propriedades da seção da viga. A partir dessa análise, definiu-se alguns subconjuntos de atributos selecionados dentro do mesmo conjunto de observações das 6120 pontes para a elaboração do modelo de RNA. A Tabela 13 mostra os atributos considerados em cada um desses subconjuntos.

É importante mencionar que, apesar da alta correlação entre o vão e os atributos relacionados com as dimensões e propriedades da seção da viga, entende-se que estas são variáveis importantes na definição do problema. Por isso, o vão e alguns atributos da viga foram considerados em todos os subconjuntos de atributos. Nos subconjuntos 5 e 6, considerou-se apenas o momento de inércia ou o módulo de resistência inferior entre os preditores que representam os atributos da viga de aço por entender que essas propriedades da seção da viga estão diretamente relacionadas com a tensão de flexão das vigas, segundo a teoria de resistência dos materiais.

Tabela 13 – Subconjunto de atributos selecionados

Atributos	Subconjunto					
	1	2	3	4	5	6
Vão	x	x	x	x	x	x
Número de faixas						
Largura	x	x	x	x	x	x
Número de vigas	x	x	x	x	x	x
Balanço	x	x	x	x	x	x
Espaçamento	x	x	x	x	x	x
Espessura tabuleiro	x	x	x	x	x	x
Módulo de elasticidade E (concreto)	x	x	x	x	x	x
Altura da alma	x	x	x	x		
Espessura da alma	x	x	x	x		
Largura da mesa superior	x	x	x	x		
Espessura da mesa superior	x	x	x	x		
Largura da mesa inferior	x	x	x	x		
Espessura da mesa inferior	x	x	x	x		
Área	x					
Centro de gravidade	x					
Momento de inércia	x	x			x	
Módulo de resistência superior	x					
Módulo de resistência inferior	x		x			x
Número de atributos	18	14	14	13	8	8

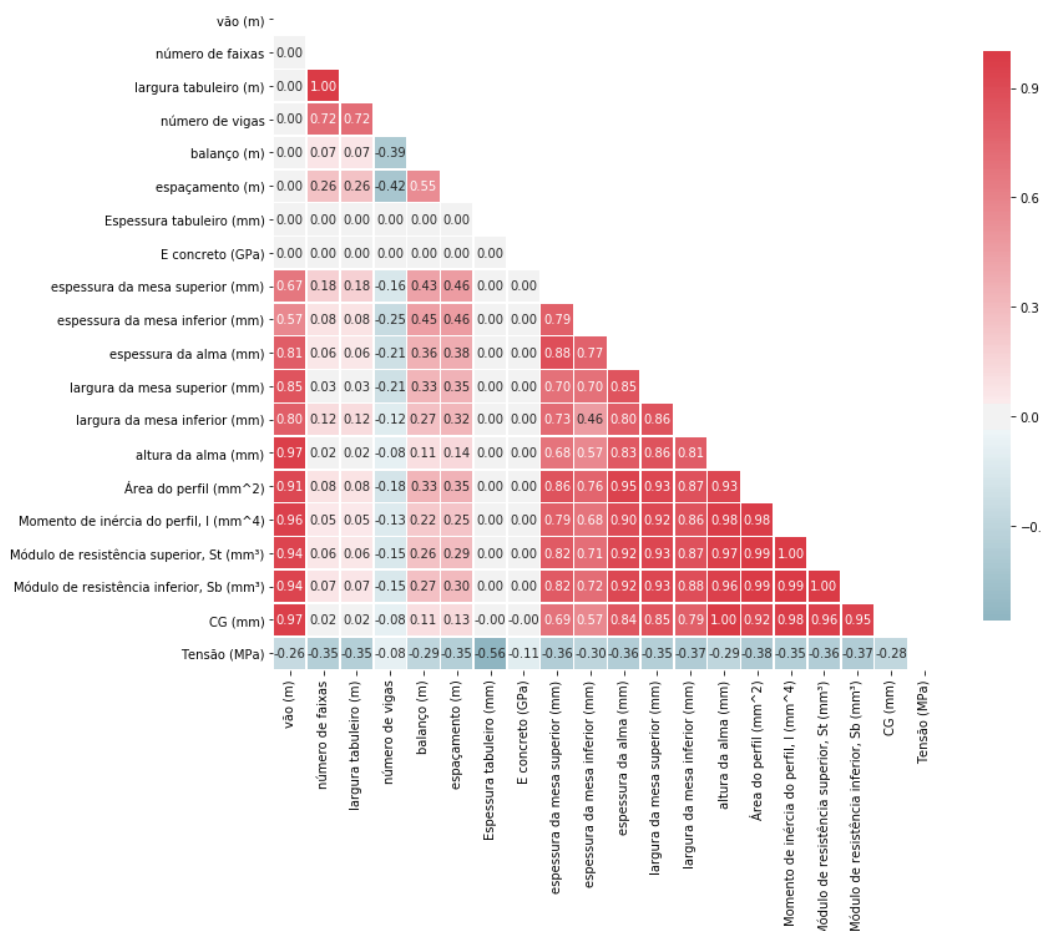


Figura 24 – Matriz de correlação das variáveis de entrada e saída

3.3.7.2

Comparação entre modelos e definição do modelo final

Para cada subconjunto de atributos foram realizados 50 experimentos baseados na permutação dos parâmetros definidos na Tabela 12 da seção 3.3.3. Dentre os hiper-parâmetros testados nos experimentos, observou-se que o uso da função de ativação tangente hiperbólica e do *solver* L-bfgs (sem parada antecipada) resultaram nas configurações de rede com melhor desempenho em todos os subconjuntos de atributos.

A Tabela 14 mostra os demais hiper-parâmetros e métricas de erro apenas das configurações de rede que apresentaram o melhor desempenho em cada subconjunto (os demais resultados podem ser encontrados no apêndice I). Além das métricas de erro, computou-se o número máximo de épocas necessárias (dentre as 5 tentativas no processo de validação cruzada) para atingir os critérios de parada definidos na seção 3.3.5.

Tabela 14 – Configurações de RNA que apresentaram os melhores resultados em cada subconjunto de atributos

Subconjunto	número de neurônios	número de épocas	R^2_{adj}	MSE*	MAPE (%)**
1	13	413	0,9805	$2,78 \cdot 10^{-6}$	1,42
2	17	427	0,9799	$2,89 \cdot 10^{-6}$	1,42
3	17	427	0,9814	$2,66 \cdot 10^{-6}$	1,35
4	19	464	0,9815	$2,65 \cdot 10^{-6}$	1,36
5	8	583	0,9240	$1,09 \cdot 10^{-5}$	2,79
6	12	529	0,9551	$6,52 \cdot 10^{-6}$	2,19

*MSE: *Mean Squared Error*

**MAPE: *Mean Absolute Percentage Error*

De acordo com o critério de escolha para definir o melhor modelo, verificou-se que o subconjunto de atributos 4 foi o que apresentou menor MSE. Tal subconjunto também obteve bom desempenho em relação aos seus valores de R^2_{adj} e MAPE. Dessa forma, utilizou-se a configuração de rede com melhor desempenho nesse conjunto de atributos para computar os parâmetros (valores dos pesos e viés) do modelo final de rede neural, realizado conforme explicado em 3.3.6.

Na predição dos valores de teste, o modelo apresentou valor de coeficiente de determinação ajustado de 0,982, erro quadrático médio de $2,47 \cdot 10^{-6}$, e erro percentual absoluto médio de 1,32. Na Figura 25, observa-se uma boa relação entre os dados reais e previstos, visto que a dispersão desses dados se aproxima da reta definida por uma equação linear em que os valores reais são iguais aos previstos. Na Figura 26, mostra-se o histograma do erro de predição, definido como a subtração entre o valor previsto e o valor real, onde percebe-se que o mesmo apresenta uma distribuição aproximadamente normal, com valor central em torno de zero.




Figura 25 – Dispersão entre os valores de tensão máxima prevista x real




Figura 26 – Histograma do erro para o modelo de RNA

Portanto, o modelo de rede neural artificial proposto neste trabalho faz a predição da tensão unitária máxima em vigas de pontes de aço simplesmente apoiadas a partir dos 13 atributos selecionados no subconjunto 4 e apresenta apenas uma camada escondida com 19 neurônios. A função de ativação entre a camada de entrada e a camada de escondida é a tangente hiperbólica. Entre a camada escondida e a camada de saída, a função de ativação é linear. Assim, novas predições de tensões máximas podem ser feitas a partir dos parâmetros obtidos por essa configuração de rede de acordo com as expressões (34), (35) e (36). Os coeficientes dos pesos e viés do modelo final podem ser encontrados no apêndice II do trabalho.

3.4

Avaliação da segurança estrutural de acordo com a análise do índice de confiabilidade

A vida útil de pontes de vigas de aço depende de diferentes fatores. Neste trabalho, a avaliação da segurança de detalhes estruturais de pontes de aço submetidos a ação dos fenômenos de fadiga e corrosão foi feita a partir de uma análise de confiabilidade estrutural. Tal análise foi feita a partir da definição de uma função de estado limite que aplica a abordagem de fadiga estabelecida pelas curvas S-N da AASHTO baseada na regra de Miner. Assim, uma medida de segurança estrutural definida pelo índice de confiabilidade foi obtida de acordo com a função de estado limite estabelecida. A inclusão do fenômeno de corrosão nessa análise foi feita a partir do ajuste dos parâmetros estatísticos de algumas variáveis de fadiga que são afetadas pela corrosão.

Ambos fenômenos de degradação causam uma redução no índice de confiabilidade ao longo do tempo, que deve ser comparado com o valor do índice

de confiabilidade alvo, β_{alvo} , também definido como o nível mínimo aceitável de segurança estrutural indicado para a ponte. De acordo com o exposto na seção 2.3, existem algumas recomendações na literatura em relação ao valor a ser adotado para o β_{alvo} e, neste trabalho, assumiu-se que β_{alvo} é equivalente a 2, o que corresponde a uma probabilidade de falha de 2,3%.

3.4.1

Confiabilidade da fadiga em pontes de aço

Neste trabalho, a avaliação da vida em fadiga de pontes de aço considerou a deterioração do detalhe estrutural representado pela solda entre a alma e a mesa inferior das vigas (longarinas) de aço presentes nessas estruturas. Como a análise de fadiga foi feita apenas para pontes simplesmente apoiadas, a faixa de tensão pode ser aproximada pela tensão máxima no meio do vão que ocorre nesse detalhe estrutural devido à passagem do tráfego de veículos, representado pelo caminhão de fadiga da AAHSTO. Além disso, a passagem de cada veículo – de comprimento menor em relação ao comprimento da ponte – é responsável por causar um ciclo de tensão na estrutura.

A avaliação da segurança estrutural devido ao dano por fadiga foi feita a partir da análise do valor do índice de confiabilidade ao longo do tempo, calculado de acordo com a função de estado limite estabelecida para esse dano. Para isso, adotou-se a abordagem estabelecida por Frangopol et al. (2016) que define a função de estado limite a partir das curvas S-N e da regra do acúmulo de ano, conforme exposto na seção 2.3, equações (11) e (12). Tal abordagem considera que as variáveis relacionadas com a avaliação da vida em fadiga (A , Δ e $\Delta\sigma_e$) devem ser modeladas como variáveis aleatórias para que se possa considerar suas variabilidades. Assim, assumiu-se que todas as variáveis aleatórias seguem uma função de distribuição lognormal e que o valor do índice de confiabilidade pode ser calculado de acordo com as equações (13), (14) e (15).

Para a aplicação dessas equações, adotou-se as informações estatísticas coletadas de inúmeros testes de fadiga realizados no período do estabelecimento da norma americana, assim como de outros trabalhos relevantes na literatura. Dessa forma, os parâmetros de média e coeficiente de variação do coeficiente do detalhe

estrutural (categoria B), A , e o acúmulo de dano crítico, Δ , são expostos na Tabela 15.

Tabela 15 – Parâmetros estatísticos das variáveis A e Δ

Parâmetros de fadiga	Média, μ	Coefficiente de variação, cov	Referências
A	$7.85 \times 10^{10} \text{ (ksi}^3\text{)}$	0.35	Keating e Fisher (1986)
Δ	1.0	0.3	Wirsching (1984)

A média e o coeficiente de variação da faixa de tensão efetiva ($\Delta\sigma_e$) são parâmetros que dependem das características locais do tráfego de determinada rodovia. Na metodologia proposta, no entanto, desconsiderou-se a variação da configuração e dos pesos dos eixos do veículo considerado para a determinação das faixas de tensão causadas pelo tráfego de veículos. A faixa de tensão efetiva diária é, portanto, equivalente à faixa de tensão calculada para a passagem de um veículo de fadiga. Dessa forma, assumiu-se que a média da tensão efetiva, $\mu_{\Delta\sigma_e}$, é igual à tensão máxima e que seu coeficiente de variação é nulo ($V_{\Delta\sigma_e} = 0$), pois não considerou-se a variação das faixas de tensão na abordagem proposta.

Em relação do número de ciclos de tensão anual acumulado, este foi estimado a partir do volume de tráfego médio diário de caminhões em uma única faixa ($ADTT_{SL}$, *Average Daily Truck Traffic in a Single Lane*, em inglês) e da taxa de crescimento anual (r) desse volume de acordo com a equação (37) (Kwon & Frangopol, 2010).

$$N(t) = 365 \cdot ADTT_{SL} \cdot \frac{(1+r)^t - 1}{\ln(1+r)} \quad (37)$$

Onde t é o número de anos, $N(t)$ é o número de ciclos acumulado no ano t e r é a taxa de crescimento anual. Para o caso de uma taxa de crescimento anual r nula, utilizou-se a equação (38) para o cálculo de $N(t)$.

$$N(t) = 365 * t * ADTT_{SL} \quad (38)$$

3.4.2 Corrosão

Como mencionado anteriormente, estruturas de pontes rodoviárias são suscetíveis, simultaneamente, aos processos de degradação por corrosão e por fadiga. A corrosão é um processo de degradação do material proveniente da interação com o meio ambiente. Em pontes de viga de aço, esse processo se

manifesta principalmente nas regiões dos apoios e ao longo do comprimento da ponte, conforme o padrão de corrosão observado por Kayser & Nowak (1989), exposto na seção 2.2 (Figura 8). Neste trabalho, adotou-se o modelo simplificado de Czarnecki e Nowak (2008) para representar a corrosão uniforme em vigas de pontes de aço.

Conforme mencionado no referencial teórico, o processo de corrosão se inicia após a deterioração do sistema de revestimento das vigas, dependendo do nível de agressividade do ambiente. Assim, a perda de espessura de material após determinado período (penetração da corrosão, R) é calculada de acordo com a equação (7), da seção 2.2.2. Os parâmetros de corrosão e o tempo de início de corrosão são definidos de acordo com o tipo de material e a agressividade do ambiente, expostos na Tabela 16, cujos dados são extraídos de Brevoort et al. (1996), Kayser & Nowak (1989) e Kogler (2015). Neste trabalho, considera-se apenas pontes com vigas constituídas de aço-carbono. Tais parâmetros representam um cenário em que não há a realização de nenhuma atividade de manutenção.

Tabela 16 - Parâmetros do modelo de corrosão (cenário sem manutenção)

Ambiente	$C_A(\mu m)$	C_B	t_i (anos)
Rural	34.0	0.65	30
Urbano/Industrial	80.2	0.59	21
Marinho	70.6	0.79	15

Para representar a desaceleração da degradação da estrutura com a aplicação de algumas atividades preventivas de manutenção, utilizou-se os dados obtidos pela pesquisa de Yanez (2016), mencionados na seção 2.2.2. Dessa forma, considerou-se dois cenários de estratégias de manutenção para pontes de vigas de aço, nos quais a penetração da corrosão ainda é representada pela equação (7), porém os coeficientes e o tempo de início de corrosão dessa equação são os mostrados na Tabela 17. A primeira estratégia de manutenção consiste na lavagem periódica das vigas de aço após a degradação do revestimento de proteção. A segunda estratégia, por outro lado, consiste na lavagem das vigas durante toda vida útil da estrutura.

Tabela 17 - Parâmetros do modelo de corrosão (cenários com manutenção)

Ambiente	$C_A(\mu m)$	C_B	t_i (anos)	
			Manutenção 1	Manutenção 2
Rural	53.6	0.45	30	40
Urbano/Industrial	95.2	0.45	21	31
Marinho	93.4	0.45	15	25

Em todos os cenários considerados (com e sem manutenção), a inclusão da corrosão na avaliação da segurança da estrutura com base na análise do índice de confiabilidade se deu a partir do ajuste das médias da faixa de tensão equivalente ($\Delta\sigma_e$) e do coeficiente de resistência à fadiga (A), assumindo-se a mesma distribuição lognormal para esses parâmetros. O coeficiente de variação (razão do desvio padrão pela média), no entanto, permaneceu o mesmo estabelecido anteriormente.

O ajuste das médias de $\Delta\sigma_e$ e A foi feito de acordo com as correções desses parâmetros apresentadas no trabalho de Hosseini et al. (2013), onde os autores relatam que a degradação provocada pela corrosão afeta a resistência à fadiga de duas formas. A primeira se refere ao aumento da faixa de tensão devido à perda de material e a segunda, à redução na resistência à fadiga devido a presença da corrosão.

O aumento na faixa de tensão foi considerado a partir do fator de amplificação nominal (NAF) definido, neste trabalho, pela razão entre o módulo de resistência inferior antes (W_0) e após (W_{corr}) a perda de material por corrosão – equação (40). O cálculo de W_{corr} se dá a partir da seção obtida pelo padrão de corrosão da Figura 27 (b). Alguns testes com modelos em elementos finitos foram realizados com o intuito de comparar o resultado da tensão máxima das vigas de pontes com redução da seção transversal obtida pela modelagem das pontes em EF e a tensão máxima calculada a partir da equação (39) e, verificou-se uma diferença relativa entre os dois procedimentos menor do que 2%. Nas equações (39) e (40), σ_{corr} é a tensão máxima da viga com corrosão, NAF é o fator de amplificação nominal, σ_0 é a tensão máxima da viga sem corrosão, W_0 é o módulo de resistência inferior da seção sem corrosão e W_{corr} , da seção corroída.




Figura 27 - Seção transversal da viga (a) sem corrosão e (b) com corrosão

$$\sigma_{corr} = NAF \cdot \sigma_0 \quad (39)$$

$$NAF = \frac{W_0}{W_{corr}} \quad (40)$$

A redução no coeficiente de resistência à fadiga foi considerada pelo fator de entalhe de corrosão CNF a partir da equação (6) (seção 2.3) para a categoria de fadiga B da AASHTO, onde $CNF_B = 1 + 0.28 \cdot R$, R representa a espessura em μm da perda de material devido a corrosão, calculada pela equação (7), e m é igual a 3. Dessa forma, a resistência de fadiga da categoria B em determinado período devido ao processo de corrosão-fadiga é dado por:

$$A_{B,corr} = \frac{A_B}{CNF_B^m} = \frac{7.85 \cdot 10^{10}}{(1 + 0.28 \cdot R)^3} \quad (41)$$

As médias dos parâmetros de fadiga presentes na equação (14), $\mu_{\Delta\sigma_e}$ e μ_A , foram ajustadas de acordo com os valores obtidos a partir das equações (39) e (41), respectivamente. É importante ressaltar que, assim como os parâmetros de fadiga, os parâmetros de corrosão C_A e C_B presentes no cálculo de R , também apresentam variabilidade pois são valores obtidos a partir de observações experimentais. No entanto, a metodologia proposta tratou estas últimas variáveis como constantes de modo a possibilitar o cálculo de β a partir de expressão (13) da seção 2.3.

3.5

Sistema de manutenção de pontes de aço

A partir dos procedimentos estabelecidos nas seções 3.3 e 3.4, definiu-se um sistema de manutenção de pontes que estima o tempo de vida útil da estrutura considerando diferentes cenários – com e sem manutenção. Tal estimativa foi feita a partir da avaliação do valor do índice de confiabilidade ao longo do tempo, que deve ser comparado com o valor de β_{alvo} que define o nível de segurança mínimo adotado para estruturas de pontes rodoviárias.

O sistema inicializa com a leitura dos dados relativos à estrutura – de geometria, material, tráfego de veículos e classificação do meio ambiente no qual a ponte está inserida – que devem ser definidos pelo usuário. Então, estima-se primeiramente a tensão unitária máxima ($\sigma_{unit\ máx}$) no detalhe estrutural analisado, que corresponde a categoria B da AASHTO, a partir da configuração de rede neural e dos atributos escolhidos na seção 3.3. Em seguida, calcula-se a tensão máxima a partir do produto entre a tensão unitária máxima, calculada pelo modelo de RNA, o peso do caminhão de fadiga da AASHTO, $P_{caminhão}$, e o fator de amplificação

dinâmica de 1,15, utilizado em análises estáticas para representar os efeitos dinâmicos provocados pela passagem do veículos na análise de fadiga (AASHTO, 2012). É preciso mencionar que o valor do fator de amplificação dinâmica pode ser maior para estruturas flexíveis e com baixo amortecimento estrutural, conforme o item C4.7.1.1 da AASHTO. Assim, esse valor poderia configurar com um dado de entrada do sistema. No entanto, para o cálculo dos resultados finais do sistema proposto nessa dissertação, adota-se apenas o valor de 1,15.

A tensão máxima calculada representa a média da faixa de tensão equivalente, $\mu_{\Delta\sigma_e}$, pela qual o detalhe estrutural é submetido pelo tráfego de veículos dada pela equação (42), em MPa. O resultado dessa equação deve ser convertido para ksi, para manter as unidades consistentes no cálculo posterior de β , pois a média do coeficiente de resistência a fadiga (A) foi considerada em ksi³.

$$\mu_{\Delta\sigma_e} = \Delta\sigma_e = \sigma_{unit\ máx} \cdot P_{caminhão} \cdot 1,15 \quad (42)$$

É válido ressaltar que o sistema avalia a segurança da estrutura a partir da consideração do fenômeno de corrosão-fadiga e, conforme mencionado na seção 2.2, estudos apontam que este regime não apresenta um limite de fadiga de amplitude constante. Por isso, adotou-se a combinação de carga “*Fatigue II*” da norma americana, onde o peso de caminhão de fadiga equivale a 240 kN, que corresponde ao caso de vida finita à fadiga – quando não há um limite de faixa de tensão abaixo da qual não ocorre falha por fadiga da estrutura.

O próximo passo corresponde ao cálculo do volume médio diário de caminhões em uma única faixa ($ADTT_{SL}$). Para isso, utiliza-se algumas diretrizes estabelecidas pela AASHTO (2012), onde a norma recomenda a estimativa desse parâmetro de acordo com a informação disponível sobre o tráfego. Caso o usuário tenha conhecimento apenas sobre o volume de tráfego médio diário (ADT) que inclui tanto veículos leves quanto pesados, é preciso estimar primeiramente o volume de tráfego médio diário de caminhões ($ADTT$) a partir do fator f_t da Tabela 18 pela equação (43) e, em seguida, estimar o valor de $ADTT_{SL}$ a partir do fator p (Tabela 19) pela equação (44), que depende do número faixas disponíveis para passagem de caminhões. Por outro lado, caso o usuário tenha conhecimento quanto ao $ADTT$, é preciso estimar apenas o $ADTT_{SL}$. O valor de $ADTT_{SL}$ é então utilizado para calcular o número de ciclos acumulado, $N(t)$, a partir das equações (37) e (38), de acordo com o valor de crescimento anual adotado pelo usuário.

Tabela 18 - Fração de caminhões (f_t) no volume de tráfego de acordo com classificação da ponte (tabela C3.6.1.4.2-1 AASHTO).

Classe da Rodovia	Fração de caminhões no tráfego, f_t
Interestadual Rural	0,20
Interestadual Urbana	0,15
Rural (outras)	0,15
Urbana (outras)	0,10

Tabela 19 - Taxa de ocupação em uma única faixa (p) de acordo com o número de faixas (tabela 3.6.1.4.2-1 AASHTO)

Número de faixas disponíveis para passagem de caminhões	p
1	1,00
2	0,85
3 ou mais	0,8

$$ADTT = ADT * f_t \quad (43)$$

$$ADTT_{SL} = ADTT * p \quad (44)$$

Com isso, utiliza-se os procedimentos estabelecidos na seção 3.4 para calcular o índice de confiabilidade β da estrutura ao longo do tempo, que é realizado de duas formas de acordo com o período analisado. Caso o ano analisado seja inferior ao tempo de início da corrosão (t_i), definido a partir do tipo de ambiente escolhido pelo usuário, realiza-se o cálculo de β de acordo com a seção 3.4.1 e, caso o contrário, de acordo com a seção 3.4.2.

Esse cálculo é interrompido no ano em que $\beta < \beta_{alvo}$, com $\beta_{alvo} = 2$, que corresponde ao ano em que a estrutura deixa de apresentar um nível de segurança satisfatório, definido pela probabilidade de falha de 2,3%. Assim, esse ano indica o tempo recomendado para que a estrutura seja retirada de serviço, assumindo condições normais de operação.

O cálculo de β é realizado três vezes: para o cenário com ausência de manutenção e para os dois cenários com estratégias de manutenção distintas, representadas pela lavagem da superestrutura com início em períodos diferentes, conforme apresentado na seção 3.4.2. O fluxograma desse sistema é apresentado na Figura 28.

Para este trabalho, utilizou-se a interface gráfica desenvolvida por Santos (2020) a partir do método proposto com intuito de facilitar o uso do sistema pelo usuário. A interface gráfica do sistema apresenta quatro abas, sendo que as três

primeiras recebem os dados de entrada e a última apresenta os resultados. Na primeira aba, deve-se inserir os dados de geometria e material (Figura 29). Na segunda aba, deve-se selecionar o tipo de ambiente no qual a estrutura está inserida (Figura 30). Já na terceira aba, deve-se selecionar o tipo de dado em relação ao volume de tráfego que o usuário tem acesso e, em seguida, inserir os dados relacionados ao número de veículos (e selecionar o tipo de rodovia) ou de caminhões, assim como a taxa de crescimento anual do tráfego (Figura 31). Por fim, a quarta aba apresenta um resumo dos principais dados da ponte assim como os resultados calculados pela metodologia – tempo de vida útil da estrutura para os três cenários de manutenção considerados (Figura 32).

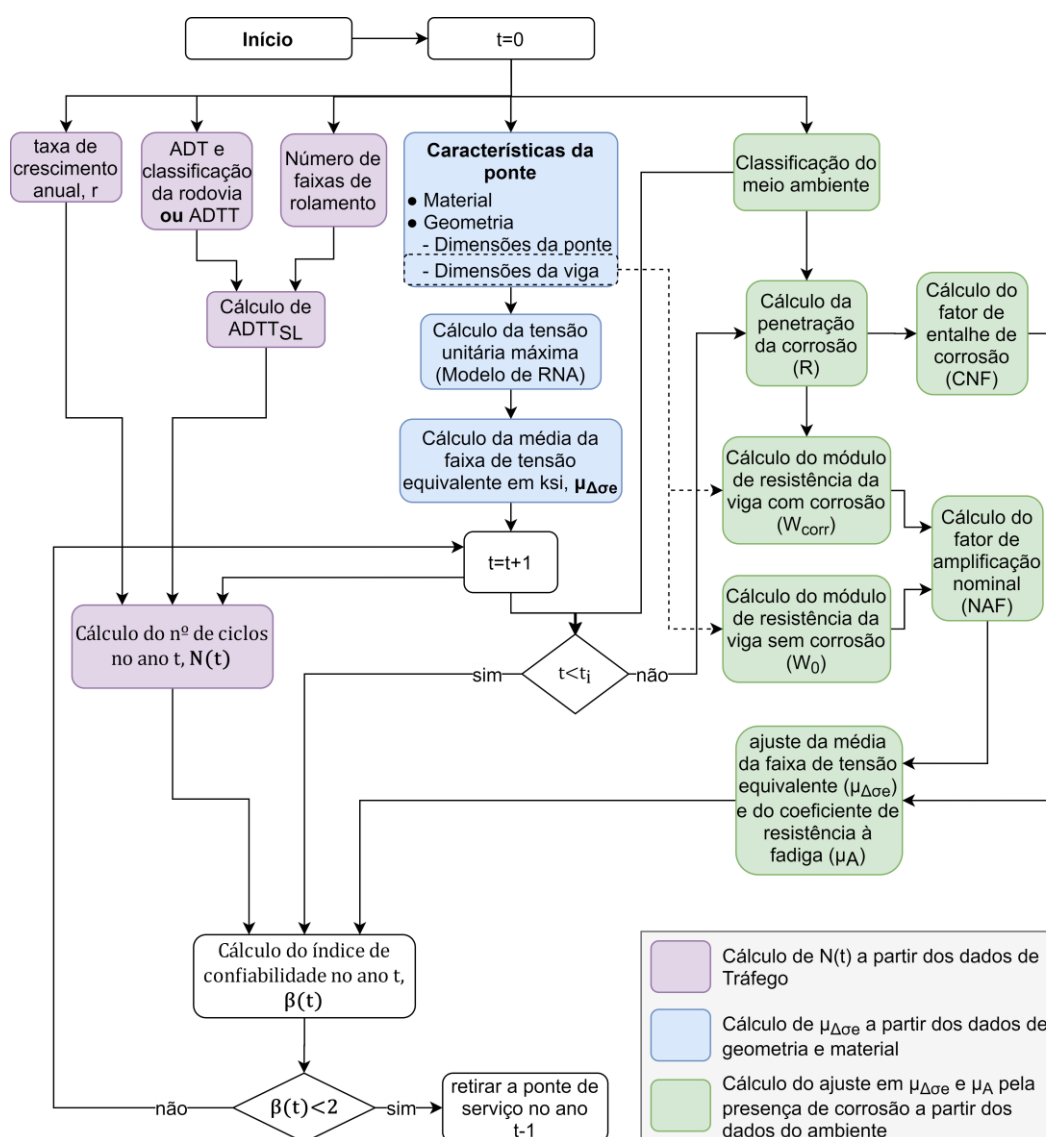


Figura 28 - Fluxograma do sistema

SISTEMA DE MANUTENÇÃO DE PONTES DE AÇO

Geometria/Material | Dados ambientais | Dados do tráfego | Resultados

GEOMETRIA

Comprimento do tabuleiro (entre 15 e 60 m) ?

Largura do tabuleiro (entre 8 e 22.4 m) ?

Número de faixas de rolamento (2, 4 ou 6) ?

Espessura do tabuleiro (entre 150 e 250 mm) ?

Número de vigas (de 3 a 12 vigas) ?

Espaçamento entre vigas (entre 1.5 e 4.5 m) ?

Balanço (entre 0.4 e 1.9 m) ?

Espessura da alma, tw (entre 8 e 28 mm) ?

Altura da alma, hw (entre 485 e 2500 mm) ?

Espessura da mesa superior, tfc (entre 10 e 46 mm) ?

Largura da mesa superior, bfc (entre 175 e 690 mm) ?

Espessura da mesa inferior, tft (entre 12 e 60 mm) ?

Largura da mesa inferior, bft (entre 175 e 758 mm) ?

MATERIAL (TABULEIRO DE CONCRETO)

Resistência à compressão do concreto, fck (entre 25 e 50 MPa)

3D model of a bridge deck with dimensions.

© Copyright 2020 - by Verônica Pinto Marques Coimbra, Eng. PdB

Figura 29 – Interface gráfica do sistema - aba "Geometria/ Material"

SISTEMA DE MANUTENÇÃO DE PONTES DE AÇO

Geometria/Material | **Dados ambientais** | Dados do tráfego | Resultados

CLASSIFICAÇÃO DO AMBIENTE DE ACORDO COM A LOCALIZAÇÃO DA PONTE

Rural (selected)

Urbano/Industrial

Marinho

3D model of a bridge over a river.

© Copyright 2020 - by Verônica Pinto Marques Coimbra, Eng. PdB

Figura 30 – Interface gráfica do sistema - aba "Dados ambientais"

SISTEMA DE MANUTENÇÃO DE PONTES DE AÇO

Geometria/Material | Dados ambientais | **Dados do tráfego** | Resultados

VOLUME DE TRÁFEGO

Volume de tráfego diário (todos os veículos) (veículos/dia)

Volume de tráfego diário de caminhões (caminhões/dia)

CLASSIFICAÇÃO DA RODOVIA

Interestadual Rural

Interestadual Urbana

Rural (outras)

Urbana (outras)

TAXA DE CRESCIMENTO ANUAL

r (%)

© Copyright 2020 - by Verissa Pinto Marques Queiroz, Puc-Rio

Figura 31 – Interface gráfica do sistema - aba "Dados do tráfego"



Figura 32 – Interface gráfica do sistema - aba "Resultados"

4

Exemplo numérico

Este capítulo apresenta a aplicação do sistema de manutenção proposto em uma ponte de aço dimensionada de acordo com a norma americana (AASHTO). Nas simulações realizadas, buscou-se avaliar o efeito do volume de tráfego, do ambiente local e das alternativas de manutenção na estimativa da vida útil da estrutura.

4.1

Estrutura considerada

A partir de uma seção transversal típica de ponte, similar a apresentada em um documento da FHWA (Barth, 2015) que apresenta um projeto de ponte de viga de aço contínua de dois vãos, dimensionou-se uma ponte simplesmente apoiada utilizada nas análises deste trabalho. Verificou-se os critérios normativos quanto aos esforços de momento fletor, cisalhamento, e quanto ao deslocamento máximo permitido. A ponte considerada possui vão de 25 metros de comprimento e 11,2 metros de largura. Dados a respeito das dimensões e propriedade dos materiais da estrutura são fornecidos na

Tabela 20, enquanto a sua seção transversal é exposta na Figura 33.




Figura 33 – Seção transversal típica de pontes de aço (adaptado de BARTH, 2015)

Tabela 20 – Dados da ponte considerada

Dimensões/ Propriedade	Valores
Vão (m)	25
Número de faixas	2
Largura defesa (m)	0,4
Largura tabuleiro (m)	11,2
Número de vigas	4
Balanço (m)	1,10
Espaçamento (m)	3
Espessura do tabuleiro (mm)	200
Resistência a compressão do concreto, fck (mpa)	25
Modulo de elasticidade do aço (gpa)	200
Espessura da mesa superior (mm)	20
Espessura da mesa inferior (mm)	30
Espessura da alma (mm)	12
Largura da mesa superior (mm)	300
Largura da mesa inferior (mm)	400
Altura da alma (mm)	1000

4.1.1 Simulações

Para a mesma estrutura, foram realizados três conjuntos de simulações para avaliar o efeito dos parâmetros de tráfego e do ambiente, assim como das alternativas de manutenção na estimativa da vida útil da estrutura (Tabela 21). Essa estimativa foi comparada com o tempo de vida útil mínimo recomendado pela AASHTO, equivalente a 75 anos.

Tabela 21 – Parâmetros variados em cada conjunto de simulação

Parâmetros	Conjunto de Simulação			
	1	2.1	2.2	3
ADTT*	1000, 2500, 5000 e 10000	1000, 2500, 5000 e 10000	1000, 2500, 5000 e 10000	1000, 2500, 5000 ou 10000
r**	0%	3%	5%	0%, 3% ou 5%
Atividades de manutenção	não	não	não	sim

*ADTT: Volume de tráfego médio diário de caminhões

**r: taxa de crescimento anual do tráfego

Em todos os conjuntos de simulações, foram considerados os três tipos de ambientes: rural, urbano/ industrial e marinho. O volume de tráfego médio diário de caminhões (ADTT) foi estimado com base no estudo realizado pelo departamento de transporte de Michigan (Eamon et al., 2014). Assim, os ADTTs

escolhidos para realizar as simulações foram equivalentes a 1000, 2500, 5000 e 10000, que correspondem a um volume de tráfego baixo, médio, alto e muito alto, respectivamente.

4.1.2

Efeito do volume de tráfego (ADTT)

O primeiro conjunto de simulações corresponde aos casos em que não há presença de qualquer atividade de manutenção, além de não ser considerado o crescimento anual no volume de tráfego ($r = 0\%$). A Tabela 22 apresenta o tempo de vida útil da estrutura para cada valor de ADTT em cada ambiente considerado. Os gráficos da Figura 34 mostram a curva do índice de confiabilidade para cada um desses cenários.

Tabela 22 – Tempo de vida útil (conjunto de simulação 1)

Ambiente	Tempo de vida útil (anos)			
	ADTT			
	1000	2500	5000	10000
Rural	435	257	166	104
Urbano	300	183	122	79
Marinho	148	104	77	56




Figura 34 – Índice de confiabilidade ao longo do tempo para os ambientes: Rural, Urbano/ Industrial e Marinho (conjunto de simulação 1)

De acordo com a tabela e figura acima, observa-se que apenas um caso apresentou tempo de vida útil inferior a 75 anos, que corresponde ao caso com ADTT de 10000 veículos em um ambiente marinho, apresentando tempo de vida útil de 56 anos. Em relação aos diferentes volumes de tráfego (ADTT) dentro do mesmo ambiente, observa-se uma redução no tempo e vida útil conforme o aumento no ADTT, sendo essa redução mais elevada no ambiente rural, chegando a 76% entre o ADTT de 1000 e 10000 veículos. Apesar do ambiente marinho proporcionar

menor durabilidade da estrutura, a redução do tempo de vida útil para o mesmo contexto é de 62%.

4.1.3

Efeito da taxa de crescimento anual do volume de tráfego

O segundo conjunto de simulações foi separado em dois experimentos e representa os casos em que também não há a presença das atividades de manutenção, porém há um crescimento no volume de tráfego. O primeiro experimento corresponde às simulações com taxa de crescimento anual de 3%, enquanto o segundo, às simulações com taxa de crescimento anual de 5%. O tempo de vida útil para cada ADTT e ambiente simulados do primeiro experimento são expostos na Tabela 23, enquanto os gráficos para cada um desses cenários são mostrados na Figura 35.

Tabela 23 – Tempo de vida útil (conjunto de simulação 2, experimento 1: $r=3\%$)

Ambiente	Tempo de vida útil (anos)			
	ADTT ($r=3\%$)			
	1000	2500	5000	10000
Rural	115	89	71	54
Urbano	103	79	62	47
Marinho	82	64	51	40




Figura 35 – Índice de confiabilidade ao longo do tempo para os ambientes: Rural, Urbano/ Industrial e Marinho (conjunto de simulação 2, experimento 1: $r=3\%$)

Para esse conjunto de simulações, observa-se um tempo de vida útil insuficiente nos ambientes rural e urbano para os ADTT de 5000 e 10000 veículos, e no ambiente marinho para os ADTT de 2500, 5000 e 10000 veículos. A maior redução no tempo de vida útil em relação ao primeiro conjunto de simulações (com taxa de crescimento anual nula) foi observada para o ADTT de 1000 veículos, onde essa redução chegou a 74% no ambiente rural, 66% no ambiente urbano/ industrial

e 45% no ambiente marinho. Com o crescimento linear do volume de tráfego a cada ano, o aumento percentual no número de ciclos acumulado é mais acentuado para os ADTTs de menor valor, o que justifica o comportamento observado.

A Tabela 24 e Figura 36 apresentam o tempo de vida útil e índice de confiabilidade, respectivamente, para cada caso simulado do segundo experimento. Com uma taxa de crescimento anual de 5%, nota-se que quase todas as simulações apontam um tempo de vida útil insuficiente, com exceção do ADTT de 1000 veículos para os ambientes rural e urbano/ industrial. Assim como no segundo conjunto de simulações apresentado anteriormente, observa-se uma redução no tempo de vida útil mais acentuada para o ADTT de 1000 veículos em relação aos mesmos cenários com taxa de crescimento anual nula. Essa redução chega a 81% no ambiente rural, 75% no ambiente urbano/ industrial e 56% no ambiente marinho.

Tabela 24 – Tempo de vida útil (conjunto de simulação 2, experimento 2: $r=5\%$)

Ambiente	Tempo de vida útil TVU (anos)			
	ADTT ($r=5\%$)			
	1000	2500	5000	10000
Rural	82	66	54	43
Urbano	76	60	49	38
Marinho	65	52	43	34




Figura 36 – Índice de confiabilidade ao longo do tempo para os ambientes: Rural, Urbano/ Industrial e Marinho (conjunto de simulação 2, experimento 2: $r=5\%$)

4.1.4 Efeito das atividades de manutenção

Para o terceiro conjunto de simulações, estimou-se o tempo de vida útil da estrutura com a presença de atividades de manutenção para alguns casos dos exemplos anteriores que apresentaram um tempo de vida útil inferior a 75 anos,

utilizando o aplicativo desenvolvido. O sistema considera duas estratégias de manutenção distintas: a primeira diz respeito à lavagem da superestrutura após a deterioração do revestimento de proteção das vigas, e a segunda, à lavagem da superestrutura durante toda a vida útil da estrutura. Nos gráficos, a primeira alternativa é identificada por “manutenção (1)”, e a segunda alternativa, por “manutenção (2)”.

Primeiramente, considerou-se dois casos simulados em um ambiente marinho. O primeiro caso refere-se ao cenário com volume de tráfego de 10000 caminhões com taxa de crescimento anual nula (Figura 37 a). Neste cenário, observou-se um aumento na vida útil de 56 para 95 e 96 anos, para a primeira e segunda alternativa de manutenção, respectivamente, o que corresponde a um aumento médio de 70,5%. No segundo caso, com volume de tráfego de 2500 caminhões e taxa de crescimento anual de 3% em ambiente marinho (Figura 37 b), as atividades de manutenção aumentaram o tempo de vida útil de 64 para 85 e 86 anos, o que corresponde a um aumento médio de 33,6%.




Figura 37 – Índice de confiabilidade ao longo do tempo no ambiente marinho com (a) ADTT=10000; $r=0\%$ e (b) ADTT=2500; $r=3\%$

Para o terceiro cenário, avaliou-se o efeito das atividades de manutenção para todos os ambientes (rural, urbano/ industrial e marinho) com ADTT de 5000 veículos e taxa de crescimento de 3% (Figura 38 e Tabela 25).

Apesar das alternativas de manutenção proporcionarem um aumento médio na vida útil de 3,5%, 8,9% e 30,4% para os ambientes rural, urbano/ industrial e

marinho, respectivamente, o tempo de vida útil das estruturas se manteve abaixo dos 75 anos recomendados. Dessa forma, observa-se que a manutenção nesse caso não causa impacto significativo quando o dano por fadiga é dominante – quando o volume de tráfego e seu crescimento anual são elevados.

Tabela 25 - Tempo de vida útil (ADTT=5000; $r=3\%$)

Ambiente	Tempo de vida útil TVU (anos)		
	Alternativa de manutenção		
	Sem manutenção	(1)	(2)
Rural	71	73	74
Urbano	62	67	68
Marinho	51	66	67




Figura 38 - Índice de confiabilidade ao longo do tempo (ADTT=5000; $r=3\%$)

É válido destacar que as alternativas de manutenção consideradas no sistema afetam apenas a degradação por corrosão. O modelo de confiabilidade utilizado pelo sistema poderia apontar um maior aumento no tempo de vida útil caso fosse introduzida alguma atividade de manutenção que afetasse os parâmetros de fadiga desse modelo. No entanto, são necessárias mais pesquisas sobre o assunto que quantifiquem o ganho de resistência no modelo de fadiga com tais manutenções.

Outros casos com diferentes contextos de valores de ADTT, taxa de crescimento anual de tráfego e tipos de ambientes foram simulados e apresentaram resultados semelhantes em relação aos três casos apresentados nesta seção (apêndice III). Para todos os casos simulados, observa-se que as duas alternativas de manutenção consideradas proporcionam um ganho similar de vida útil, sobretudo no ambiente marinho de até 30%. A escolha da melhor alternativa de manutenção deve avaliar, além do ganho no tempo de vida útil, o custo da

implementação da manutenção, que está fora do escopo deste trabalho. No entanto, como ambas alternativas consideradas diferem apenas no período de início da lavagem da superestrutura, espera-se que a primeira alternativa, onde a lavagem inicia apenas após a deterioração do sistema de revestimento das vigas, apresente menor custo em relação à segunda alternativa. Dessa forma, o sistema permite, mesmo que de forma limitada, a análise dessas questões para a escolha da alternativa de manutenção adequada de acordo com o objetivo e orçamento do usuário.

5 Conclusão

O monitoramento estrutural dos elementos de um sistema de infraestrutura ao longo do tempo permite a identificação prévia de danos ou anomalias para que sejam tomadas ações de manutenção em obras de construção civil, de forma a garantir sua segurança e operação. No entanto, não são raros os casos em que há falta de informação quanto ao estado de conservação dessas estruturas. Nesse contexto, este trabalho apresentou o desenvolvimento de um protótipo de sistema capaz de estimar o tempo de vida útil de pontes de viga de aço simplesmente apoiadas devido aos danos de fadiga e corrosão, danos mais comuns nesse tipo de estrutura segundo a literatura, considerando algumas alternativas de manutenção.

A metodologia elaborada neste trabalho integra o uso de um modelo de rede neural e de um modelo de confiabilidade estrutural para o desenvolvimento de um sistema de manutenção. Nesse sistema, o modelo de RNA realiza a predição da tensão de tração na solda entre a alma e mesa inferior da viga (detalhe de fadiga considerado) no meio do vão, enquanto o modelo de confiabilidade estrutural realiza a predição do tempo de vida útil da estrutura, considerando uma probabilidade de falha de 2,3%.

O método dos elementos finitos foi utilizado para obter os resultados de tensão com a passagem de um veículo de fadiga no detalhe estrutural considerado a partir de modelos desenvolvidos no *software* ABAQUS. A técnica de modelagem utilizada nos modelos foi validada e se mostrou capaz de reproduzir os resultados dos testes de carga realizados em uma ponte real. Para o treinamento e validação do modelo de rede neural, elaborou-se um banco de dados baseado nos resultados desses modelos em EF para diferentes configurações de pontes de aço, onde os dados de geometria e material correspondem aos dados de entrada da RNA. Verificou-se que a configuração de rede escolhida – rede *Multilayer Perceptron* com uma camada escondida de 13 neurônios e tangente hiperbólica como função de ativação – é capaz de estimar os resultados de tensão com boa precisão, apresentando erro quadrático médio de $2,47 \cdot 10^{-6}$ e R^2 ajustado de 0,982.

Com o intuito de avaliar a influência dos parâmetros que afetam os danos por fadiga e corrosão no sistema, caracterizados pelos dados de tráfego e do ambiente, respectivamente, realizou-se uma simulação numérica com uma ponte de aço projetada de acordo com a AASHTO. Os resultados das simulações possibilitaram as conclusões descritas a seguir. Primeiramente, observou-se que o aumento do volume de tráfego (ADTT) e da sua taxa de crescimento anual reduzem o tempo de vida útil da estrutura, podendo chegar a uma redução de até 76% para o aumento no ADTT e de até 81% para o aumento na taxa de crescimento anual.

Além disso, observou-se que o ambiente que apresentou menor durabilidade da estrutura sob o mesmo contexto de volume de tráfego foi o ambiente marinho, seguido dos ambientes urbano/ industrial e rural, respectivamente. Em relação ao aumento no tempo de vida útil proporcionado pelas alternativas de manutenção, o ambiente marinho foi o que apresentou o maior aumento. A lavagem da superestrutura – alternativa de manutenção considerada no trabalho – desacelera o processo de corrosão ao retirar parte dos poluentes presentes na atmosfera que se depositam na estrutura, sendo o ambiente marinho o que apresenta a maior concentração desses poluentes.

A diferença entre o tempo de vida útil proporcionado por cada atividade de manutenção considerada no sistema é pequena (diferença média de 1 ano) para todos os ambientes. É válido mencionar que tais atividades afetam apenas o dano por corrosão, logo não apresentam um impacto considerável no aumento da durabilidade da estrutura quando o dano por fadiga é dominante, representado pelo alto volume de tráfego e alta taxa de crescimento anual do tráfego.

O sistema de manutenção proposto fornece informações a respeito da durabilidade da estrutura sob condições mínimas de segurança e pode ser utilizado como ferramenta de apoio à decisão no planejamento das ações de manutenção de pontes de aço, a partir da análise do tempo de vida útil estimado com a presença ou ausência de atividades de manutenção. O sistema fornece tais informações a partir de uma forma simples de utilização, que requer apenas informações a respeito da geometria da ponte, da resistência do concreto do tabuleiro, dos dados de tráfego e da classificação do ambiente, na qual não há necessidade de conhecimento técnico especializado nos assuntos envolvidos – análise estrutural, de confiabilidade e treinamento da rede neural.

A substituição da simulação e análise de um modelo em EF por um modelo de rede neural treinado para obter os resultados de tensão nas vigas de aço pode significar uma economia de tempo e esforço computacional. Além disso, não é necessário qualquer tipo de licença para execução do sistema final, pois o mesmo pode ser executado utilizando apenas linguagens de código aberto, como o Python.

Embora o sistema desenvolvido contemple apenas a lavagem da superestrutura como atividades de manutenção, cabe ressaltar que existem outras atividades que podem fazer parte de um sistema de gestão de obras de arte especiais. No entanto, a inclusão de outras ações de manutenção no sistema requer estudos que quantifiquem a influência dessas ações nos parâmetros de resistência dos modelos de fadiga e corrosão considerados.

Por fim, é preciso lembrar que o sistema proposto se baseia em várias hipóteses e por isso os resultados das simulações representam o comportamento de um grupo de pontes de aço. Os resultados das tensões obtidas pelo modelo de RNA representam apenas uma amostra de pontes através do banco de dados utilizado. Da mesma forma, os resultados quanto ao tempo de vida útil se baseiam em parâmetros do modelo de fadiga e corrosão que podem variar dependendo do tipo de detalhe estrutural analisado e dos dados locais do ambiente que a estrutura se encontra. Ainda assim, o método proposto para o sistema pode ser aplicado e estendido para outros dados de pontes e parâmetros.

5.1 Sugestões para trabalhos futuros

A análise da durabilidade de pontes de aço é um tópico relevante para a gestão de pontes de um sistema de infraestrutura. Assim, novos estudos podem fornecer dados mais adequados para melhorar a tomada de decisão quanto às ações de manutenção e garantir a segurança e operação dessas estruturas. Nesse sentido, algumas recomendações para trabalhos futuros incluem:

- Inclusão de outros carregamentos e configurações para caminhões de fadiga caso a informação esteja disponível, de maneira a ajustar o cálculo da média e do coeficiente de variação da tensão equivalente.
- Aplicação da metodologia proposta para outras configurações de ponte sobre vigas de aço, com mais de um vão por exemplo. Nesse caso, o modelo de RNA deveria ser treinado para prever os valores de tensão máximas (região entre os

apoios) e mínimas (região dos apoios), além do número de ciclos com a passagem do caminhão, necessários para o cálculo da tensão equivalente.

- Integração do sistema com um banco de dados existente de pontes reais para treinar o modelo de rede neural, de forma obter uma amostra representativa das pontes analisadas.
- Estudos a respeito de outras alternativas de manutenção em relação à sua influência nos parâmetros de resistência do modelo de fadiga (curva S-N) e de corrosão (Kayser, 1988) para ampliar as possibilidades de atividades de manutenção do sistema.
- Estudo a respeito do custo de cada atividade de manutenção para complementar as informações fornecidas pelo sistema de manutenção.

AKINCI, N. O.; LIU, J.; BOWMAN, M. D. Parapet Strength and Contribution to Live-Load Response for Superload Passages. **Journal of Bridge Engineering**, v. 13, n. 1, p. 55–63, 2008.

ALBRECHT, P.; NAEEMI, A. H. **Performance of Weathering Steel in Bridges**. Washington, DC: National Cooperative Highway Research Program Report 272, 1984.

ALBRECHT, Pedro; LENWARI, A. Fatigue Strength of Trolley Bridge Stringers Made of ASTM A7 Steel. **Journal of Bridge Engineering**, v. 13, n. 1, p. 67–74, 2008.

_____. Fatigue strength of weathered A588 steel beams. **Journal of Bridge Engineering**, v. 14, n. 6, p. 436–443, 2009.

ALBRECHT, Pedro; SHABSHAB, C. FATIGUE STRENGTH OF WEATHERED ROLLED BEAM MADE OF A588 STEEL. **Journal of Materials in Civil Engineering**, v. 6, n. 3, p. 407–428, 1994.

AMERICAN ASSOCIATION OF STATE HIGHWAY AND TRANSPORTATION OFFICIALS. **LRFD Bridge Design Specifications**. 6. ed. Washington, DC: [s.n.], 2012.

AMERICAN CONCRETE INSTITUTE. **ACI 318-14: Building Code Requirements for Structural Concrete**. Farmington Hills: [s.n.], 2014.

ANG, A.-S.; DE LEON, D. Modeling and analysis of uncertainties for risk-informed decisions in infrastructures engineering. **Structure and Infrastructure Engineering**, v. 1, n. 1, p. 19–31, 2005.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 8800: Projeto de estruturas de aço e de estruturas mistas de aço e concreto de edifícios**. 2. ed. Rio de Janeiro: [s.n.], 2008.

AZIZINAMINI, A.; KATHOL, S.; BEACHAM, M. Effect of Cross Frames on Behavior of Steel Girder Bridges. 1995, Washington, DC: Transportation Research Board, 1995. p. 117–124.

BAKER, M. **LRFD Design Example for Steel Girder Superstructure Bridge - US Customary units**. Washington, DC: FHWA/ National Highway Institute, 2003.

BARTH, K. **Steel Bridge Design Handbook Design Example 2A: Two-Span Continuous Straight Composite Steel I-Girder Bridge**. Washington, DC: Federal Highway Administration, 2015. v. 21. Disponível em: <<http://www.fhwa.dot.gov/bridge/steel/pubs/if12052/volume02.pdf>>5Cnhttps://trid.trb.org/view/1247094>.

BREVOORT, G. H.; MELAMPY, M. F.; SHIELDS, K. R. Updated protective

coating costs, products, and service life. 1996, Houston: CORROSION 96. Paper No. 477. NACE international, 1996. p. 21.

BS5400. Steel, Concrete and Composite Bridge. Part 10: Code of practice for fatigue. London: British Standards Institute, 1980.

CHA, H. et al. Effect of local damage caused by overweight trucks on the durability of steel bridges. **Journal of Performance of Constructed Facilities**, v. 30, n. 1, p. 1–11, 2016.

CHUNG, H.-Y. **Fatigue Reliability and Optimal Inspection Strategies for steel bridges.** 2004. The University of Texas at Austin, 2004.

CHUNG, W.; LIU, J.; SOTELINO, E. D. Influence of secondary elements and deck cracking on the lateral load distribution of steel girder bridges. **Journal of Bridge Engineering**, v. 11, n. 2, p. 178–187, 2006.

CHUNG, W.; SOTELINO, E. D. Three-dimensional finite element modeling of composite girder bridges. **Engineering Structures**, v. 28, n. 1, p. 63–71, 2005.

CYBENKO, G. Approximation by superpositions of a sigmoidal function. **Mathematics of Control, Signals, and Systems**, v. 2, p. 303–314, 1989.

CZARNECKI, A. **System reliability models for evaluation of corroded steel girder bridges.** 2006. 251 f. University of Michigan, 2006. Disponível em: <<http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:System+Reliability+Models+for+Evaluation+of+Corroded+Steel+Girder+Bridges#8>>.

CZARNECKI, A. A.; NOWAK, A. S. Time-variant reliability profiles for steel girder bridges. **Structural Safety**, v. 30, n. 1, p. 49–64, 2008.

DENG, L.; YAN, W.; NIE, L. A simple corrosion fatigue design method for bridges considering the coupled corrosion-overloading effect. **Engineering Structures**, v. 178, p. 309–317, 2019. Disponível em: <<https://doi.org/10.1016/j.engstruct.2018.10.028>>.

EAMON, C. D.; KAMJO, V.; SHINKI, K. **Side By Side Probability for Bridge Design and Analysis.** . Detroit: [s.n.], 2014.

EAMON, C. D.; NOWAK, A. S. Effect of secondary elements on bridge structural system reliability considering moment capacity. **Structural Safety**, v. 26, n. 1, p. 29–47, 2004.

EL AGHOURY, I. M.; GALAL, K. Corrosion-fatigue strain-life model for steel bridge girders under various weathering conditions. **Journal of Structural Engineering**, v. 140, n. 6, 2014.

EUROPEAN COMMITTEE FOR STANDARDIZATION. **Design of steel structures - Part 1-9: Fatigue.** Bruxelas: EN 1993-1-9, 2005.

FEDERAL HIGHWAY ADMINISTRATION. **Bridge Preservation Guide Maintaining a Resilient Infrastructure to Preserve Mobility.** . [S.l: s.n.], 2018.

FINOTTI, R. P.; CURY, A. A.; BARBOSA, F. de S. An SHM approach using machine learning and statistical indicators extracted from raw dynamic measurements. **Latin American Journal of Solids and Structures**, v. 16, n. 2, p. 1–17, 2019.

FISHER, J. W.; KULAK, G. L.; SMITH, I. F. C. **A Fatigue Primer for Structural**

Engineers A Note of Caution. . [S.l.]: National Steel Bridge Alliance, 1998.

FRANGOPOL, D. M.; SOLIMAN, M. Life-cycle of structural systems: recent achievements and future directions. **Structure and Infrastructure Engineering**, v. 12, n. 1, p. 1–20, 2016.

FRANGOPOL, D. M.; ZHU, B.; SOLIMAN, M. Redundancy of Structures and Fatigue of Bridges and Ships Under Uncertainty. In: GHANEM, R.; HIGDON, D.; OWHADI, H. (Org.). . **Handb. Uncertain. Quantif.** Cham: Springer International Publishing, 2016. p. 1–25. Disponível em: <<http://link.springer.com/10.1007/978-3-319-11259-6>>.

GHOSN, M.; MOSES, F.; FRANGOPOL, D. M. Redundancy and robustness of highway bridge superstructures and substructures. **Structure and Infrastructure Engineering**, v. 6, n. 1–2, p. 257–278, 2010.

GONZÁLEZ, A.; CANTERO, D.; OBRIEN, E. J. Dynamic increment for shear force due to heavy vehicles crossing a highway bridge. **Computers and Structures**, v. 89, n. 23–24, p. 2261–2272, 2011.

GRUBB, M. A. et al. **Load and Resistance Factor Design (LRFD) For Highway Bridge Superstructures - Reference Manual.** . Arlington: [s.n.], 2015.

GUO, T.; FRANGOPOL, D. M.; CHEN, Y. Fatigue reliability assessment of steel bridge details integrating weigh-in-motion data and probabilistic finite element analysis. **Computers and Structures**, v. 112–113, p. 245–257, 2012. Disponível em: <<http://dx.doi.org/10.1016/j.compstruc.2012.09.002>>.

HAHIN, C. **Effects of Corrosion and Fatigue on the Load Carrying Capacity of Structural and Reinforcing Steel.** . [S.l.: s.n.], 1994.

HAWK, H.; SMALL, E. P. The BRIDGIT Bridge Management System. **Structural Engineering International: Journal of the International Association for Bridge and Structural Engineering (IABSE)**, v. 8, n. 4, p. 309–314, 1998.

HAYKIN, S. **Neural networks and learning machines.** third edit ed. New Jersey: Prentice Hall, 2009.

HOSSEINI, A.; SAHRAPEYMA, A.; MAREFAT, M. S. A reliability-based methodology for considering corrosion effects on fatigue deterioration in steel bridges - Part I: Methodology - Part I. **International Journal of Steel Structures**, v. 13, n. 4, p. 645–656, 2013.

KAYSER, J. R.; NOWAK, A. S. Reliability of corroded steel girder bridges. **Structural Safety**, v. 6, n. 1, p. 53–63, 1989.

KEATING, P. B.; FISHER, J. W. **Review of Fatigue Tests and Design Criteria on Welded Details, Final Report, July 1986, 180p. (NCHRP Report 286) Publication 86-21. Fritz Laboratory Report.** Bethlehem: [s.n.], 1986. Disponível em: <http://digital.lib.lehigh.edu/fritz/pdf/488_1_86_.pdf>.

KOMP, M. E. Atmospheric corrosion ratings of weathering steels - Calculations and significance. **Materials Performance**, v. 26, n. 7, p. 42–44, 1987.

KWON, K.; FRANGOPOL, D. M. Bridge fatigue reliability assessment using probability density functions of equivalent stress range based on field monitoring data. **International Journal of Fatigue**, v. 32, n. 8, p. 1221–1232, 2010.

LEITÃO, F. N. **Modelagem do Comportamento Dinâmico e Análise de Fadiga**

de Pontes Rodoviárias Mistas (aço-concreto). 2014. 209 f. Pontifícia Universidade Católica do Rio de Janeiro (PUC-Rio), 2014.

LIU, Y. et al. Fatigue Reliability Assessment of Orthotropic Bridge Decks under Stochastic Truck Loading. **Shock and Vibration**, v. 2016, 2016.

LU, N.; LIU, Y.; DENG, Y. Fatigue Reliability Evaluation of Orthotropic Steel Bridge Decks Based on Site-Specific Weigh-in-Motion Measurements. **International Journal of Steel Structures**, v. 19, n. 1, p. 181–192, 2019.

LU, N.; NOORI, M.; LIU, Y. Fatigue reliability assessment of welded steel bridge decks under stochastic truck loads via machine learning. **Journal of Bridge Engineering**, v. 22, n. 1, p. 1–12, 2016.

MANSOUR, A. E. et al. **Probability Based Ship Design: Implementation of Design Guidelines.** Ship Structure Committee. Washington, DC: [s.n.], 1996. Disponível em: <internal-pdf://0187262376/392.pdf>.

MEHRJOO, M. et al. Damage detection of truss bridge joints using Artificial Neural Networks. **Expert Systems with Applications**, v. 35, n. 3, p. 1122–1131, 2008.

MINER, M. Cumulative Damage in Fatigue. **Journal of Applied Mechanics**, p. 159–164, 1945.

MODJESKI; MASTERS. **Bridges for Service Life Beyond 100 Years: Service Limit State Design.** The second Strategic Highway Research Program. Washington, DC: [s.n.], 2015.

MOSES, F.; SCHILLING, C. G.; RAJU, K. S. **Fatigue evaluation procedures for steel bridges.** . Washington, DC: National Cooperative Highway Research Program Report 299, 1987.

MÜLLER, A. C.; GUIDO, S. **Introduction to Machine Learning with Python.** 1. ed. United States of America: O'Reilly Media, 2017.

NOWAK, A. S.; COLLINS, K. R. **Reliability of Structures.** 1. ed. United States of America: The McGraw-Hill Companies, 2000.

NOWAK, A.; SZERSZEN, M. Reliability profiles for steel girder bridges with regard to corrosion and fatigue. **Journal of Theoretical and Applied Mechanics**, v. 39, n. 2, p. 339–352, 2001.

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

PARK, C. H. et al. Time-varying reliability model of steel girder bridges. **Proceedings of the Institution of Civil Engineers: Structures and Buildings**, v. 128, n. 4, p. 359–367, 1998.

RAKOCZY, A. M.; NOWAK, A. S.; DICK, S. Fatigue reliability model for steel railway bridges. **Structure and Infrastructure Engineering**, v. 12, n. 12, p. 1602–1613, 2016. Disponível em: <<http://dx.doi.org/10.1080/15732479.2016.1153664>>.

REVIE, R. W.; UHLIG, H. H. **Corrosion and corrosion control. An introduction to corrosion science and engineering.** Third Edit ed. New Jersey: John Wiley & Sons, 2008.

ROBERT KOGLER. **Steel Bridge Design Handbook: Corrosion Protection of Steel Bridges**. 2015. Disponível em:

<<https://www.fhwa.dot.gov/bridge/steel/pubs/hif16002/volume09.pdf>>.

RUSSO, F. M. et al. **Design and Evaluation of Steel Bridges for Fatigue and Fracture - Reference Manual**. 2016. Disponível em:

<<https://www.fhwa.dot.gov/bridge/steel/pubs/nhi16016.pdf>>.

SANTOS, G. V. **Desenvolvimento de um aplicativo desktop para um sistema de manutenção de pontes de aço baseado em múltiplas linguagens de programação**. Rio de Janeiro, 2020.

SANTOS, M. S. **Estudo da Aplicabilidade do Método Simplificado da AASHTO para Distribuição Transversal de Cargas Móveis para Pontes no Brasil**. 2015. 125 f. Pontificia Universidade Católica do Rio de Janeiro (PUC-Rio), 2015.

SCHILLING, C. G. et al. **Fatigue of Welded Steel Bridge Members under Variable-amplitude Loadings**. . Washington, DC: National Cooperative Highway Research Program Report 188, 1978.

SHARIFI, Y.; RAHGOZAR, R. Fatigue notch factor in steel bridges due to corrosion. **Archives of Civil and Mechanical Engineering**, v. 9, n. 4, p. 75–83, 2009. Disponível em: <[http://dx.doi.org/10.1016/S1644-9665\(12\)60071-5](http://dx.doi.org/10.1016/S1644-9665(12)60071-5)>.

SNYDER, R. E.; LIKINS, G. E. J.; MOSES, F. Loading Spectrum Experienced by Bridge Structures in the United States. 1985.

SPEARMAN, C. The Proof and Measurement of Association between Two Things. **The American Journal of Psychology**, v. 15, n. 1, p. 72–101, 1904.

STEPHENS, R. I. et al. **Metal Fatigue in Engineering**. 2. ed. United States of America: John Wiley & Sons, 2001.

SZERSZEN, M. M.; NOWAK, A. S.; LAMAN, J. A. Fatigue reliability of steel bridges. **Journal of Constructional Steel Research**, v. 52, n. 1, p. 83–92, 1999.

SZERSZEN, M.; NOWAK, A. S. Fatigue evaluation of steel and concrete bridges. **Transportation Research Record**, v. 1, p. 73–80, 2000.

THE COMMITTEE ON FATIGUE AND FRACTURE RELIABILITY OF THE COMMITTEE ON STRUCTURAL SAFETY AND RELIABILITY OF THE STRUCTURAL DIVISION OF ASCE. Fatigue Reliability: Introduction. **Journal of Structural Division**, v. 108, p. 3–88, 1982.

THOMPSON, P. D. et al. The Pontis Bridge Management System. **Structural Engineering International: Journal of the International Association for Bridge and Structural Engineering (IABSE)**, v. 8, n. 4, p. 303–308, 1998.

WANG, W. et al. Truck Weight Limit for Simply Supported Steel Girder Bridges Based on Bridge Fatigue Reliability. **Journal of Aerospace Engineering**, v. 31, n. 6, p. 04018079, 2018.

WIRSCHING, P. H. Fatigue reliability for offshore structures. **Journal of Structural Engineering**, v. 110, n. 10, p. 2340–2356, 1984.

YAN, W. et al. Probabilistic machine learning approach to bridge fatigue failure analysis due to vehicular overloading. **Engineering Structures**, v. 193, n. 1, p. 91–99, 2019. Disponível em: <<https://doi.org/10.1016/j.engstruct.2019.05.028>>.

YANEZ, L. M. M. **Bridge maintenance to enhance corrosion resistance and performance of steel girder bridges**. 2016. 349 f. Purdue University, 2016. Disponível em: <https://docs.lib.purdue.edu/open_access_dissertations/977>.

YANG, H.; YAN, W.; HE, H. Parameters identification of moving load using ANN and dynamic strain. **Shock and Vibration**, v. 2016, 2016.

YE, X. W.; SU, Y. H.; HAN, J. P. A state-of-the-art review on fatigue life assessment of steel bridges. **Mathematical Problems in Engineering**, v. 2014, 2014.

ZHANG, W.; YUAN, H. Corrosion fatigue effects on life estimation of deteriorated bridges under vehicle impacts. **Engineering Structures**, v. 71, p. 128–136, 2014.

ZHU, J.; ZHANG, W. Probabilistic fatigue damage assessment of coastal slender bridges under coupled dynamic loads. **Engineering Structures**, v. 166, p. 274–285, 2018. Disponível em: <<https://doi.org/10.1016/j.engstruct.2018.03.073>>.

ZURASKI, P. D.; JOHNSON, J. E. Fatigue strength of deteriorated steel highway bridges. **Journal of Structural Engineering**, v. 118, n. 5, p. 1432–1433, 1990.

Apêndice I – Resultados da validação cruzada dos modelos de RNA

Neste Anexo, apresenta-se os 15 melhores resultados da validação cruzada dos modelos de rede neural realizada para cada subconjunto de atributos.

Tabela 26 - Resultados do subconjunto de atributos 1

Solver	Função de ativação	Número de neurônios	Parada antecipada	Máximo número de épocas	R_{adj}^2	MSE	MAPE
L-bfgs	tanh	13	Não	413	0.981	2.78E-06	1.422
L-bfgs	tanh	27	Não	398	0.978	3.24E-06	1.484
L-bfgs	tanh	18	Não	473	0.977	3.28E-06	1.484
L-bfgs	tanh	22	Não	365	0.976	3.38E-06	1.526
L-bfgs	tanh	9	Não	500	0.967	4.86E-06	1.832
L-bfgs	logistic	18	Não	333	0.952	6.90E-06	2.192
L-bfgs	logistic	27	Não	329	0.950	7.17E-06	2.240
L-bfgs	logistic	9	Não	391	0.950	7.23E-06	2.241
L-bfgs	logistic	13	Não	249	0.945	7.93E-06	2.358
L-bfgs	logistic	22	Não	219	0.944	7.99E-06	2.413
Adam	tanh	22	Sim	157	0.936	9.20E-06	2.570
Adam	tanh	18	Sim	201	0.925	1.08E-05	2.832
Adam	logistic	18	Sim	306	0.924	1.09E-05	2.771
Adam	logistic	9	Sim	473	0.921	1.14E-05	2.813
Adam	tanh	27	Sim	224	0.919	1.16E-05	2.832

Tabela 27 - Resultados do subconjunto de atributos 2

Solver	Função de ativação	Número de neurônios	Parada antecipada	Máximo número de épocas	R_{adj}^2	MSE	MAPE
L-bfgs	tanh	17	Não	427	0.980	2.89E-06	1.417
L-bfgs	tanh	21	Não	396	0.976	3.46E-06	1.601
L-bfgs	tanh	7	Não	623	0.974	3.69E-06	1.626
L-bfgs	tanh	14	Não	430	0.972	4.04E-06	1.737
L-bfgs	tanh	10	Não	457	0.972	4.05E-06	1.708
L-bfgs	logistic	21	Não	240	0.947	7.61E-06	2.311
L-bfgs	logistic	10	Não	327	0.945	7.90E-06	2.347
L-bfgs	logistic	14	Não	266	0.945	7.86E-06	2.380
L-bfgs	logistic	17	Não	215	0.945	7.94E-06	2.376
L-bfgs	logistic	7	Não	212	0.944	8.16E-06	2.424
Adam	logistic	7	Sim	371	0.930	1.00E-05	2.680

Adam	tanh	17	Sim	236	0.921	1.13E-05	2.910
Adam	tanh	14	Sim	220	0.919	1.15E-05	2.892
Adam	tanh	7	Sim	326	0.910	1.29E-05	2.932
Adam	tanh	21	Sim	268	0.895	1.49E-05	3.313

Tabela 28 - Resultados do subconjunto de atributos 3

Solver	Função de ativação	Número de neurônios	Parada antecipada	Máximo número de épocas	R_{adj}^2	MSE	MAPE
L-bfgs	tanh	17	Não	427	0.981	2.66E-06	1.353
L-bfgs	tanh	10	Não	421	0.980	2.83E-06	1.409
L-bfgs	tanh	21	Não	447	0.980	2.88E-06	1.406
L-bfgs	tanh	14	Não	491	0.979	3.07E-06	1.476
L-bfgs	tanh	7	Não	526	0.978	3.18E-06	1.520
L-bfgs	logistic	17	Não	316	0.957	6.14E-06	2.077
L-bfgs	logistic	7	Não	323	0.956	6.24E-06	2.117
L-bfgs	logistic	10	Não	259	0.955	6.38E-06	2.092
L-bfgs	logistic	14	Não	285	0.951	7.05E-06	2.244
L-bfgs	logistic	21	Não	321	0.944	8.09E-06	2.423
Adam	tanh	7	Sim	326	0.941	8.47E-06	2.371
Adam	tanh	17	Sim	236	0.918	1.18E-05	2.974
Adam	tanh	14	Sim	224	0.916	1.23E-05	2.924
Adam	tanh	21	Sim	268	0.898	1.45E-05	3.262
Adam	logistic	17	Sim	320	0.869	1.84E-05	3.575

Tabela 29 - Resultados do subconjunto de atributos 4

Solver	Função de ativação	Número de neurônios	Parada antecipada	Máximo número de épocas	R_{adj}^2	MSE	MAPE
L-bfgs	tanh	19	Não	464	0.982	2.65E-06	1.358
L-bfgs	tanh	13	Não	502	0.981	2.77E-06	1.419
L-bfgs	tanh	16	Não	442	0.978	3.11E-06	1.463
L-bfgs	tanh	9	Não	420	0.973	3.88E-06	1.677
L-bfgs	tanh	6	Não	404	0.968	4.53E-06	1.805
L-bfgs	logistic	9	Não	320	0.962	5.47E-06	1.954
L-bfgs	logistic	16	Não	279	0.952	6.91E-06	2.230
L-bfgs	logistic	19	Não	340	0.950	7.08E-06	2.233
L-bfgs	logistic	13	Não	320	0.941	8.45E-06	2.398
Adam	tanh	19	Sim	185	0.934	9.47E-06	2.578
Adam	tanh	16	Sim	326	0.924	1.10E-05	2.814
Adam	tanh	9	Sim	240	0.919	1.16E-05	2.920
Adam	tanh	13	Sim	319	0.894	1.53E-05	3.312
Adam	tanh	6	Sim	285	0.877	1.80E-05	3.536
L-bfgs	logistic	6	Não	172	0.860	2.07E-05	3.919

Tabela 30 - Resultados do subconjunto de atributos 5

Solver	Função de ativação	Número de neurônios	Parada antecipada	Máximo número de épocas	R^2_{adj}	MSE	MAPE
L-bfgs	tanh	8	Não	583	0.924	1.09E-05	2.794
L-bfgs	tanh	12	Não	253	0.919	1.16E-05	2.801
L-bfgs	tanh	10	Não	181	0.916	1.20E-05	2.875
L-bfgs	logistic	10	Não	311	0.913	1.24E-05	2.981
L-bfgs	logistic	8	Não	227	0.911	1.28E-05	3.123
L-bfgs	tanh	6	Não	186	0.911	1.28E-05	2.977
L-bfgs	logistic	12	Não	234	0.910	1.30E-05	3.076
L-bfgs	logistic	6	Não	291	0.899	1.45E-05	3.374
L-bfgs	tanh	4	Não	304	0.885	1.65E-05	3.554
L-bfgs	logistic	4	Não	251	0.885	1.64E-05	3.537
Adam	tanh	6	Sim	435	0.867	1.91E-05	3.850
Adam	tanh	12	Sim	160	0.840	2.30E-05	4.240
Adam	tanh	4	Sim	449	0.832	2.41E-05	4.324
Adam	tanh	10	Sim	299	0.831	2.41E-05	4.249
Adam	logistic	6	Sim	688	0.826	2.55E-05	4.419

Tabela 31 – Resultados do subconjunto de atributos 6

Solver	Função de ativação	Número de neurônios	Parada antecipada	Máximo número de épocas	R^2_{adj}	MSE	MAPE
L-bfgs	tanh	12	Não	529	0.955	6.52E-06	2.192
L-bfgs	tanh	10	Não	344	0.940	8.64E-06	2.454
L-bfgs	tanh	8	Não	681	0.937	8.89E-06	2.581
L-bfgs	logistic	10	Não	431	0.933	9.68E-06	2.693
L-bfgs	logistic	8	Não	206	0.932	9.73E-06	2.703
L-bfgs	logistic	12	Não	218	0.929	1.01E-05	2.737
L-bfgs	tanh	6	Não	210	0.926	1.06E-05	2.749
L-bfgs	tanh	4	Não	292	0.918	1.17E-05	2.995
L-bfgs	logistic	4	Não	283	0.913	1.24E-05	3.051
L-bfgs	logistic	6	Não	244	0.901	1.43E-05	3.348
Adam	tanh	6	Sim	403	0.884	1.67E-05	3.545
Adam	tanh	10	Sim	301	0.876	1.77E-05	3.574
Adam	tanh	4	Sim	455	0.868	1.88E-05	3.677
Adam	tanh	12	Sim	195	0.866	1.92E-05	3.852
Adam	logistic	10	Sim	488	0.830	2.42E-05	4.356

Apêndice II – Matriz de pesos e viés do modelo de RNA

Tabela 32 – Matriz dos pesos da primeira camada, $W^{[1]}$

0.085	0.205	-0.160	-0.250	0.697	0.425	-0.015	0.107	0.209	0.251	1.999	0.784	0.101	0.193	-1.111	-0.342	-0.311	0.919	0.194
0.325	0.440	0.223	-0.078	0.176	-0.008	0.274	-0.220	0.298	-0.136	0.056	-0.085	0.126	0.030	-0.340	-0.402	0.084	-0.083	0.047
0.391	0.248	-0.425	-0.119	0.006	0.020	0.247	0.113	-0.440	-0.414	-0.155	0.398	0.069	0.023	0.079	-0.118	-0.191	-0.262	-0.005
-0.159	0.012	0.050	-0.213	0.034	0.499	-0.183	0.020	-0.017	0.171	-0.059	0.035	-0.255	0.266	-0.176	-0.095	0.089	1.779	-0.195
-0.182	-0.342	0.274	-0.350	-0.001	0.017	-0.387	0.489	0.021	0.073	-0.322	-0.947	-0.084	0.174	-0.132	-0.331	-0.328	0.161	0.049
-0.167	0.110	-0.134	0.271	0.104	0.739	-0.088	0.046	0.310	-0.250	0.168	0.026	0.046	-0.634	0.166	-0.038	0.156	0.752	-0.353
0.276	-0.031	0.064	-0.031	-0.221	0.175	0.249	0.029	0.232	-0.063	0.021	0.001	-0.339	-0.069	0.100	-0.157	0.127	0.147	-0.389
-0.075	0.016	0.095	-0.334	0.237	0.254	-0.044	0.016	-0.209	-0.181	0.392	0.189	0.148	-0.229	0.602	-0.036	0.376	0.589	0.200
-0.132	0.177	-0.227	0.100	0.251	-0.002	0.198	-0.448	0.141	-0.929	0.143	0.199	0.515	0.184	-0.179	-0.227	0.657	1.033	-0.072
-0.251	-0.184	-0.463	0.037	0.126	-0.117	0.417	-0.433	-0.357	-0.437	0.484	0.162	-0.147	0.084	0.136	0.038	0.240	0.591	-0.069
-0.027	-0.171	-0.226	0.270	0.553	0.340	-0.165	-0.239	-0.437	0.173	0.151	0.546	-0.041	-0.500	-0.479	-0.281	0.178	0.368	0.081
0.395	0.412	-0.374	0.110	0.106	-0.281	0.157	-0.547	-0.117	0.277	0.253	0.143	0.257	-0.567	0.359	-0.197	0.235	0.664	-0.213
0.456	0.232	-0.450	-0.303	0.487	-0.459	-0.121	-1.076	-0.113	-0.108	0.791	0.103	0.333	-0.963	-0.316	-0.298	0.401	0.722	0.109

Tabela 33 – Matriz dos pesos da segunda camada, $W^{[2]}$

-0.145
0.022
0.273
-0.340
0.009
0.627
0.067
1.055
-0.106
0.454
0.703
0.453
-0.071
0.559
-0.528
-0.512
-0.474
-0.644
0.022

Tabela 34 – Vetor de Viés da primeira camada, $b^{[1]}$

-0.210
-0.156
-0.081
-0.327
0.342
0.870
0.242
0.401
-0.684
-0.015
-0.614
0.348
-0.153
-0.375
-0.451
-0.934
0.394
0.304
0.103

Tabela 35 – Vetor de Viés da segunda camada, $b^{[2]}$

0.245

Apêndice III – Simulações com uso do sistema

- Caso 4 ($r=3\%$; $ADTT=10000$)




Figura 39 - Índice de confiabilidade ao longo do tempo (caso 4)

Tabela 36 - Tempo de vida útil (caso 4)

Ambiente	Tempo de vida útil TVU (anos)		
	Alternativa de manutenção		
	Sem manutenção	(1)	(2)
Rural	54	55	56
Urbano	47	50	51
Marinho	40	49	51

- Caso 5 ($r=5\%$; $ADTT=1000$; Ambiente Marinho)




Figura 40 - Índice de confiabilidade ao longo do tempo (caso 5)

Tabela 37 - Tempo de vida útil (caso 5)

Alternativa de manutenção	Tempo de vida útil (anos)
Sem manutenção	65
(1)	80
(2)	80

- Caso 6 ($r=5\%$; ADTT=2500)




Figura 41 - Índice de confiabilidade ao longo do tempo (caso 6)

Tabela 38 - Tempo de vida útil (caso 6)

Ambiente	Tempo de vida útil TVU (anos)		
	Alternativa de manutenção		
	Sem manutenção	(1)	(2)
Rural	66	67	68
Urbano	60	63	64
Marinho	52	64	64

- Caso 7 ($r=5\%$; ADTT=5000)




Figura 42 - Índice de confiabilidade ao longo do tempo (caso 7)

Tabela 39 - Tempo de vida útil (caso 7)

Ambiente	Tempo de vida útil TVU (anos)		
	Alternativa de manutenção		
	Sem manutenção	(1)	(2)
Rural	54	55	55
Urbano	49	51	52
Marinho	43	51	51

- Caso 8 ($r=5\%$; $ADTT=10000$)




Figura 43 - Índice de confiabilidade ao longo do tempo (caso 8)

Tabela 40 - Tempo de vida útil (caso 8)

Ambiente	Tempo de vida útil TVU (anos)		
	Alternativa de manutenção		
	Sem manutenção	(1)	(2)
Rural	43	43	44
Urbano	38	40	41
Marinho	34	39	40