

APLICAÇÃO DE REDES NEURAIIS EM MODELOS PREDITIVOS DE DETERIORAÇÃO DE PONTES RODOVIÁRIAS

Maurício Bonatte

Doutorando
UMinho
Guimarães - PT
mbonatte@ymail.com

Ademir Santos

Doutorando
UMinho
Guimarães - PT
adsantos28@gmail.com

João F. C. Neto

Doutorando
CEFET-MG
Belo Horizonte - BR
joao.carvalho@ifmg.edu.br

Hélder Sousa

Investigador Auxiliar
UMinho
Guimarães - PT
sousa.hms@gmail.com

Túlio Bittencourt

Professor Titular
USP
São Paulo - BR
tbitten@usp.br

José C. Matos

Professor Auxiliar
UMinho
Guimarães - PT
jmatos@civil.uminho.pt

SUMÁRIO

A funcionalidade da malha rodoviária é vital para o desenvolvimento econômico e social de um país. Portanto, uma gestão otimizada das pontes é determinante para garantir o estado operacional da rede de transportes, visto a grande importância destes elementos no modal. Os estudos prospectivos de desenvolvimento econômico para o planejamento da manutenção, reparo e reabilitação de pontes consideram a previsão do estado de condição dos ativos rodoviários como um dos fatores determinantes para a gestão. Com o intuito de contribuir para o planejamento econômico, esse trabalho tem como objetivo a obtenção de modelos de degradação mais confiáveis, baseados em Redes Neurais Artificiais (RNA). Para o desenvolvimento deste trabalho, foi utilizada uma base de dados representativa do parque de obras no Brasil, incluindo inspeções visuais de mais de treze mil pontes. Com o modelo calibrado realizaram-se simulações de deterioração para diferentes cenários. Fica evidenciado que os modelos de degradação desenvolvidos seguindo a metodologia proposta fornecem uma previsão precisa da deterioração das pontes.

Palavras-chave: Modelos Preditivos, Deterioração, RNA, Pontes Rodoviárias, BMS

1. INTRODUÇÃO

Um sistema de gestão de pontes (BMS - *Bridge Management System*) bem-sucedido depende fortemente do planejamento de manutenções e intervenções para garantir a segurança

estrutural, funcionalidade e durabilidade das pontes, mantendo o menor investimento financeiro relacionado ao orçamento disponível [1]. Contando com um plano de controle de qualidade adequado e uma classificação de risco, pode-se garantir uma vida prolongada das pontes e, conseqüentemente, uma alocação adequada de recursos [2].

A deterioração das pontes é o resultado da constante degradação das suas propriedades devido às condições normais de operação. O processo de deterioração consiste em transformações físicas e químicas combinadas que ocorrem em todos os elementos das pontes. A situação é considerada moderadamente complexa visto cada elemento ter uma taxa de decaimento distinta. Em virtude desses processos graduais de deterioração, as pontes são submetidas a inspeções periódicas. O objetivo da inspeção é detectar defeitos que possam aparecer ao longo da vida útil da ponte. Os registros dessas inspeções podem ser usados para desenvolver modelos de deterioração de pontes, permitindo extrapolar o Índice de Condição (IC) da ponte ao longo dos anos. Prever com precisão a taxa de deterioração da ponte é, portanto, vital para o sucesso de qualquer BMS.

Uma das chaves para o sucesso da gestão destes ativos é a utilização de modelos preditivos que permitem prever, para diferentes períodos, o desempenho dos mesmos. Assim, decisões subsequentes relacionadas a periodicidade e extensão das ações de manutenção baseiam-se inteiramente no modelo de deterioração estabelecido, das conseqüências desencadeadas em caso de falha e dos custos de cada tipo de intervenção [3].

Inúmeros pesquisadores têm se esforçado para aprimorar a modelagem de deterioração das pontes brasileiras. A referência [4] apresenta os resultados das taxas de deterioração das pontes utilizando o método das cadeias de Markov. Durante o estudo, foram coletados inúmeros relatórios de inspeções em pontes, totalizando 1.707 pontes inspecionadas em uma média de 7 anos. Por outro lado, a referência [5] analisou as manifestações patológicas e as deficiências estruturais de pontes e viadutos das rodovias federais de Pernambuco. Os resultados obtidos permitiram aos autores apresentar a situação atual das pontes e subsidiar a tomada de decisão dos órgãos públicos responsáveis, garantindo assim maior durabilidade e vida útil às pontes.

Além disso, a referência [6] apresenta a situação das pontes nas rodovias federais brasileiras, com base em dados obtidos do Departamento Nacional de Infraestrutura de Transportes (DNIT), Instituto de Pesquisas Rodoviárias (IPR), Agência Nacional de Transportes Terrestres (ANTT), entre outros, que constituem um cadastro com 5.619 pontes, com níveis de informação que variam em dimensões, resultados de inspeções, croquis, fotos e coordenadas geográficas. A análise dos autores proporcionou um conhecimento mais significativo sobre a realidade das pontes nas rodovias federais brasileiras, produzindo subsídios para o planejamento de um sistema de gestão de pontes mais compatível com a realidade.

Com um banco de dados com 10.331 pontes, a referência [7] aplicou modelos de Markov e Redes Neurais Artificiais (RNA) para o estudo da degradação de pontes. Os autores concluíram que um dos principais fatores que influenciam na degradação das pontes é o grau de agressividade do ambiente. Os autores ainda propuseram uma modificação ao índice de corrosividade de Brooks, acrescentando o litoral brasileiro como uma zona de agressividade “muito alta”.

Neste contexto, o presente estudo visa aplicar um modelo probabilístico baseado em RNA para prever a deterioração de pontes, trazendo consigo um banco de dados ainda mais robusto e atualizado com 13.405 pontes e mais de 30 mil inspeções catalogadas. Os resultados da investigação podem auxiliar os proprietários de pontes e agências de transporte na alocação eficiente de recursos de manutenção.

2. BANCO DE DADOS

O Brasil apresenta um expressivo conjunto de 120 mil pontes [8] distribuídas em cinco regiões com diversas condições climáticas e sociais. Entretanto, não se tem o registro de muitas dessas pontes. Na contramão desta realidade e através do esforço dos autores e da colaboração das instituições públicas e privadas de gestão da malha rodoviária brasileira, o presente artigo reuniu um inventário detalhado de 13.405 pontes.

O banco de dados inclui informações sobre: localização geográfica, comprimento total, largura do tabuleiro, tipo de material, tipo de superestrutura, tipo de encontro, padrão de carga de tráfego, ano de construção, tipo de concessão e condição estrutural das pontes. A quantidade de informações do conjunto de dados varia de pontes apresentando apenas seu nome, localização, comprimento total e largura até pontes com informações mais detalhadas, incluindo resultados de inspeções realizadas, com anexo de croquis e fotos.

As principais diferenças entre o atual banco de dados e o banco de dados apresentado por [7] são a presença de pontes do estado de São Paulo com concessão privada e a apresentação de dados antes em branco (não informados). Um desses parâmetros é o ano de construção das pontes, ilustrado na Figura 1. Observa-se que 30% das pontes têm mais de 50 anos, diferente do exibido anteriormente por [7], que apresentou um valor de 63%.

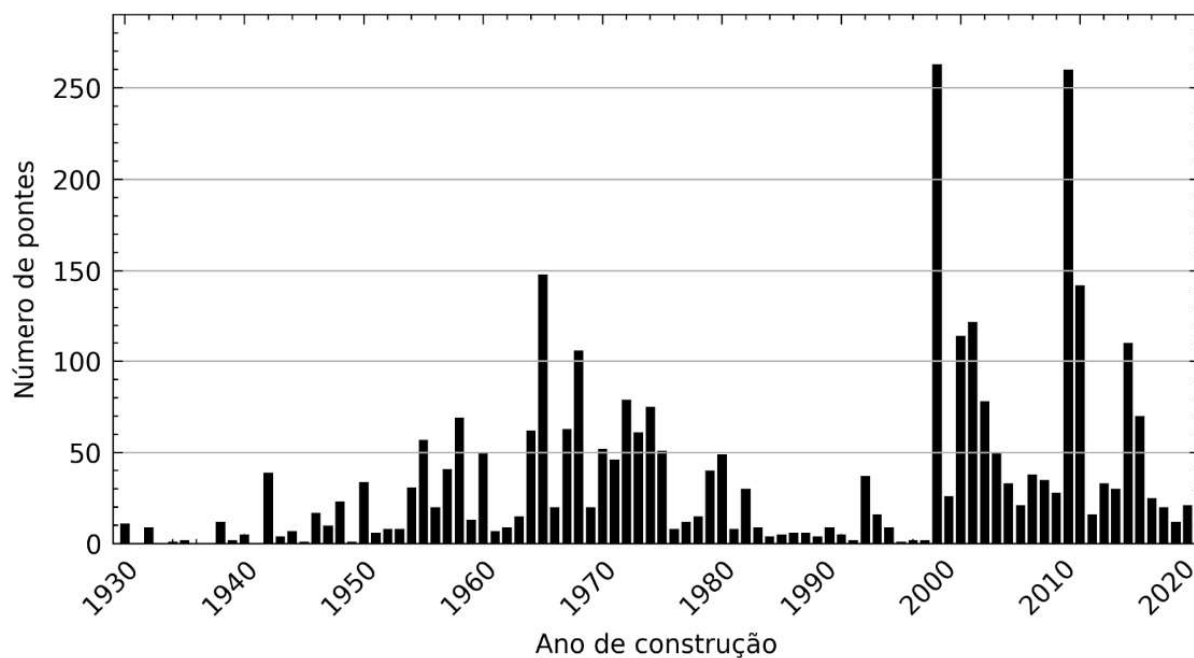


Figura 1. Número de pontes por ano de construção

Os dados disponíveis indicam que 88% das pontes apresentam comprimento até 100 metros, sendo que dentre esse subconjunto as pontes com extensão inferiores a 50 m são preponderantemente observadas (67%), conforme Figura 2 (esquerda). Em relação aos materiais constituintes dos elementos de superestruturas nota-se um prevalecente percentual de pontes de concreto armado ou protendido dentre as estruturas que possuem cadastro dessa informação, ver Figura 2 (direita). Ressalta-se, sobretudo, que há considerável percentual de dados em branco (não informados).




Figura 2. Distribuição das pontes em relação ao comprimento (esquerda) e material da superestrutura (direita)

A Figura 3 apresenta a distribuição das pontes em relação ao Volume Médio Diário (VMD). Esses dados são usados para avaliar a distribuição do tráfego, medir a demanda por uma estrada e programar melhorias básicas. O histograma mostra que pontes com VMD inferior a 5.000 e 10.000 corresponde a 68% e 84%, respectivamente.




Figura 3. Distribuição das pontes em relação ao Volume Diário Médio (VMD)

2.1 Inspeções

Dada a importância estratégica e econômica da inspeção de pontes, vários governos e centros de pesquisa se dedicam a padronizar técnicas de inspeção e sistemas de

monitoramento e gerenciamento de pontes. A maioria deles está vinculada a órgãos governamentais ou subordinada diretamente aos departamentos de transporte dos países, juntamente com acordos entre governos e universidades.

Atualmente, há três normas que regulam a inspeção de pontes no Brasil, a DNIT-010 [9], a NBR 9452 [10] e a norma publicada pela Agência de Transportes do Estado de São Paulo (ARTESP) [1].

A norma DNIT-010 [9] tem sido utilizada para avaliar pontes localizadas em rodovias sob jurisdição do Governo Federal. De acordo com esta norma, as pontes são classificadas com base em Índices de Condição (IC) que variam de 1 a 5, onde 1 corresponde a uma condição de estabilidade precária e 5 a uma condição de estabilidade excelente. A regulamentação prescreve/especifica inspeções a cada dois anos.

A norma NBR 9452 [10] propõe a avaliação da segurança estrutural de forma semelhante à [9], embora acrescente indicadores relacionados à durabilidade e funcionalidade. As pontes também são classificadas de acordo com IC que variam de 1 a 5, onde 1 corresponde a uma condição crítica e 5 a uma condição excelente. A periodicidade proposta das inspeções de rotina é de um ano, independente da classe.

A norma publicada em 2007 pela ARTESP [11] é responsável por regular as rodovias estaduais concedidas no Estado de São Paulo, acrescentando o conceito de “intervenção urgente”. A norma prevê um total de oito ICs, variando de C0 (ruim e urgência de intervenção imediata) a A5 (excelente estado e urgência de intervenção em 5 anos). A periodicidade das inspeções de rotina é de um ano, portanto seguindo os requisitos da NBR 9452 [10].

A Figura 4 traz a periodicidade das inspeções contidas no banco de dados. As primeiras inspeções apresentadas no inventário datam de 2008, abrangendo aproximadamente 13 anos e resultando em mais de 30 mil inspeções. Como se pode concluir, as inspeções visuais são realizadas em sua maioria anualmente, conforme discutido.

Quanto à divergência das normas em relação aos ICs, a referência [7] apresenta uma comparação qualitativa entre os diversos critérios de avaliação das normas. Os mesmos critérios utilizados por [7] foram utilizados no presente trabalho para a equivalência dos ICs, obtendo uma escala final de 1 a 5.

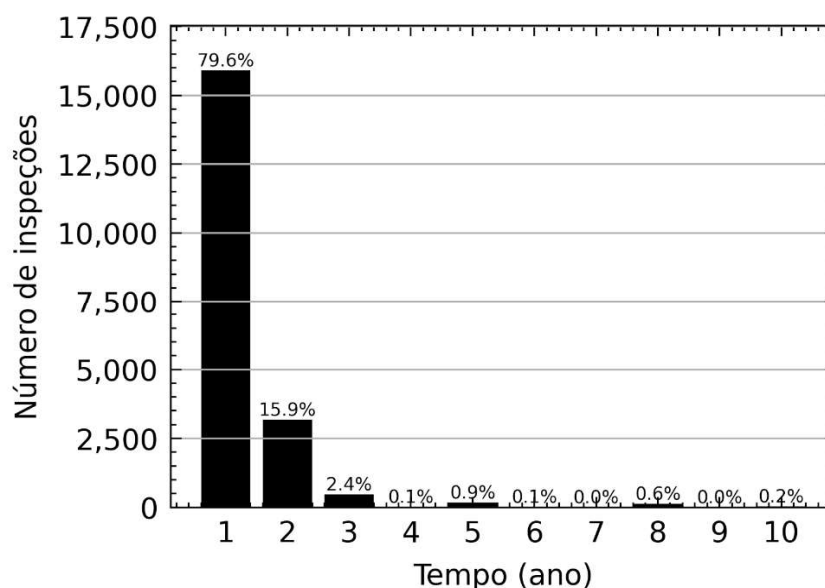


Figura 4. Periodicidade das inspeções

2.2 Filtragem das inspeções

Antes de implementar os modelos preditivos, foi realizado um processo de filtragem no banco de dados a fim de remover inconsistências. Por exemplo, as pontes sem inspeções ou com apenas uma inspeção foram removidas. Em algumas situações foi observada uma melhoria no IC das pontes quando da inspeção seguinte. Este último efeito pode ser atribuído a ações de manutenção não contempladas no inventário ou imprecisão na avaliação do estado da ponte devido à subjetividade dos inspetores na técnica de inspeção visual [12]. Visto o banco de dados não diferenciar um caso do outro, resolveu-se considerar todas as transições positivas como atividades de reparo [12,13] e dividir a ponte em duas novas pontes, uma antes e uma após a melhoria.

3. MODELOS DE DETERIORAÇÃO

Abordagens para calcular taxas de deterioração de pontes podem ser classificadas principalmente em duas categorias gerais: métodos determinísticos e métodos estocásticos [14]. Os modelos determinísticos dependem de uma relação matemática entre os fatores que afetam a degeneração da ponte. O resultado de tais modelos é descrito por valores determinísticos que representam condições médias esperadas. No entanto, os modelos determinísticos negligenciam a incerteza inerente à natureza da deterioração estocástica, são computacionalmente caros ao atualizar o modelo e ignoram a interação entre os diferentes componentes da ponte [14]. Nas subseções a seguir, o modelo baseado em RNA é adequadamente discutido.

3.1 Redes neurais artificiais

Os modelos baseados em RNA têm como principal fonte de inspiração as redes neurais biológicas na tentativa de imitar a capacidade do cérebro humano de reconhecer, associar e

generalizar padrões. A referência [15] define a rede neural como um processador distribuído paralelo, constituído por unidades de processamento simples, que têm a propensão natural de armazenar conhecimento experimental e disponibilizá-lo para uso.

A RNA é uma técnica estatística não linear capaz de resolver problemas complexos, capaz de aprender e, portanto, generalizar [15]. A generalização refere-se ao fato de que a rede neural produz saídas (*outputs*) adequadas para entradas (*inputs*) que não estavam presentes durante o treinamento.

O modelo de previsão de RNA pode ser desenvolvido para prever o estado de condição das pontes rodoviárias. Neste trabalho, foi utilizada uma rede neural de classificação multi-classe (Figura 5). A linguagem Python [16] e o Scikit-learn [17] foram utilizados para construir o modelo de predição da RNA.

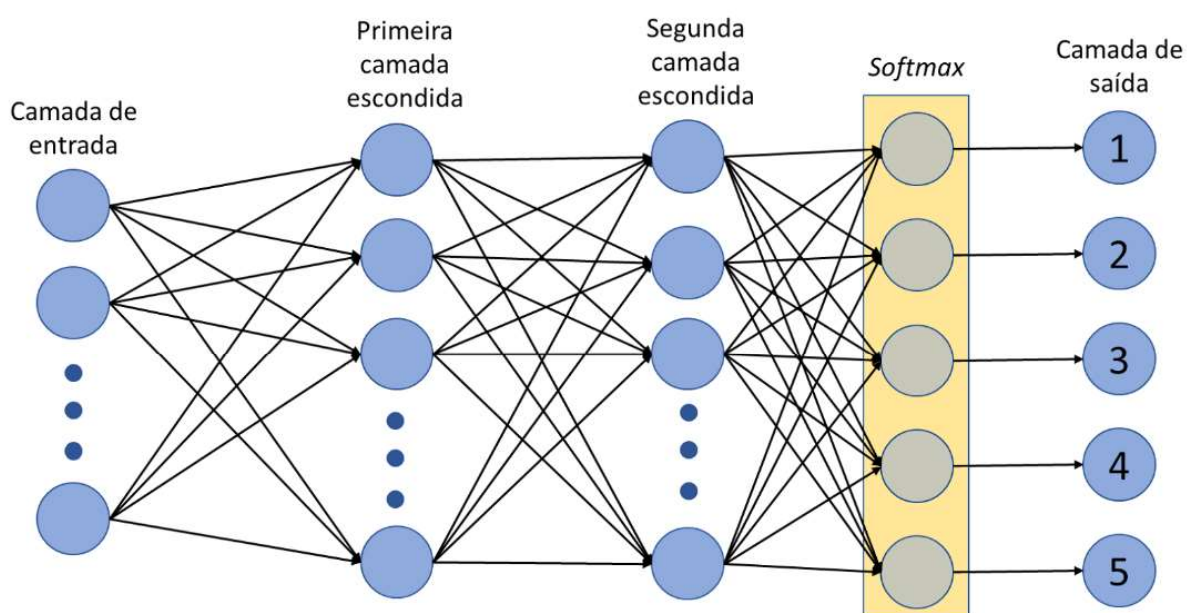


Figura 5. Perceptron multicamadas com duas camadas ocultas e função softmax

O modelo representado na Figura 5 tem na sua camada de saída a função *softmax* (Equação (1)). A função *softmax* é uma função logística que normaliza um valor de entrada em um vetor que segue uma distribuição de probabilidade que totaliza 1.

$$\sigma(Z)_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (1)$$

onde, σ é a função *softmax*, z é o vetor de entrada, e^z é a função exponencial padrão para cada elemento do vetor de entrada, K é o número de classes no classificador multi-classe e $\sum e^z$ é a função exponencial padrão para o vetor de saída.

Para além da função *softmax*, uma outra função foi adicionada para recalculer a saída do vetor de probabilidade, impondo uma probabilidade 0 a qualquer saída de probabilidade que melhore o estado de condição do ativo, visto que o ativo não pode melhorar sem que haja uma intervenção. Assim, a saída é um vetor [P(5), P(4), P(3), P(2), P(1)], que apresenta a probabilidade dos estados de condição futuros 5, 4, 3, 2 e 1, respectivamente.

3.2 Modelos estatísticos

A verificação estatística de um modelo baseado em RNA é essencial para validar e garantir uma extrapolação aceitável. Muitos testes estatísticos de ajuste são aplicados a dados categóricos para avaliar a probabilidade de acontecer qualquer diferença entre o modelo e os dados observados.

Muitos testes estatísticos podem avaliar um modelo em relação aos dados observados. Um teste estatístico comumente usado é o teste de ajuste qui-quadrado [18]. O teste de ajuste qui-quadrado é aplicado para avaliar o ajuste entre um conjunto de observações (amostra) e uma distribuição teórica, comparando a distribuição dos dados amostrais com a distribuição teórica à qual a amostra supostamente pertence. O teste é uma medida global da discrepância entre as frequências observadas na amostra e as frequências esperadas (Equação (2)).

$$\chi^2 = \sum_{i=1}^n \frac{(O_i - E_i)^2}{E_i} \quad (2)$$

onde χ^2 é o valor qui-quadrado, n é o número total de células na tabela de contingência, E_i são as frequências esperadas e O_i são as frequências observadas.

A limitação do teste qui-quadrado é não considerar a incerteza inerente aos possíveis resultados da variável. Como o banco de dados apresenta um grande número de pontes que permanecem na mesma condição (de uma inspeção para outra), usar o teste qui-quadrado obteria bons resultados mesmo com um modelo que prevê consistentemente o resultado majoritário [19].

Dessa forma, a utilização da entropia cruzada pode superar esse problema por meio da medição da dissimilaridade entre os dados da amostra e do modelo. A entropia cruzada avalia o modelo através de um conjunto de testes quanto a sua precisão (com base no cálculo da probabilidade) na previsão dos dados dos testes, calculando a “incerteza” (ou “informação”) de possíveis resultados [20]. A entropia (H) é o valor esperado de “informação” e é avaliada usando a seguinte Equação (3):

$$H(X) = E[I(X)] = \frac{-1}{N} \sum_{i=1}^n \ln(p(x_i)) \quad (3)$$

onde X é o conjunto de teste, E é o operador de valor esperado, I é o conteúdo de informação de X , N é o tamanho do conjunto de teste e $p(x_i)$ é a probabilidade do valor previsto x_i do modelo.

Embora a entropia seja crucial na avaliação da qualidade de um modelo, o inverso da perplexidade (IPP) (Equação (4)) será usado para avaliar o desempenho da generalização. O inverso da perplexidade representa a probabilidade de gerar o resultado esperado e deve ser maximizado. Em outras palavras, melhores modelos tendem a atribuir maiores probabilidades ao conjunto de testes.

$$IPP(X) = \frac{1}{PP(X)} = \exp(-H(X)) \quad (4)$$

onde IPP representa o inverso da perplexidade e PP simboliza a perplexidade.

3.3 Divisão do conjunto de dados

Com o teste estatístico definido, o próximo passo é distinguir entre o desempenho do modelo durante a fase de treinamento e a fase de teste. Uma prática comum para evitar o *overfitting* do modelo é dividir o conjunto de dados em um conjunto de treinamento (80%) e um conjunto de teste (20%). Para além disso, uma técnica de validação cruzada estratificada *k-fold* [17] é aplicada ao conjunto de dados de treinamento (Figura 6), preservando a percentagem de amostras para cada IC. O método usa diferentes partes dos dados (A, B, C e D) para treinar e validar um modelo em diferentes iterações. A validação cruzada ilustra como o modelo pode se comportar nos cenários de pior e melhor caso quando aplicado a novos dados [19]. Para resumir a precisão da validação cruzada dos modelos, a média (μ) e o desvio padrão (σ) são calculados.



Figura 6. Divisão de treino/teste e validação cruzada

3.4 Pré-processamento

O pré-processamento dos dados corresponde a atividade referente a padronização dos dados de entrada (*inputs*). Em geral, as RNA se beneficiam da normalização do conjunto de dados pois, se uma variável apresenta uma variância com ordem de grandeza maior do que as outras, ela pode dominar a função objetivo e tornar a RNA incapaz de aprender como esperado. Neste trabalho foi aplicada uma transformação de padronização para tornar a média zero e variância unitária. A Figura 7 traz uma ilustração do pré-processamento.




Figura 7. Distribuição da Idade das pontes antes (esquerda) e após (direita) o pré-processamento

3.5 Arquitetura da rede neural

Para a obtenção de uma arquitetura otimizada, uma metodologia baseada na tentativa e erro foi adotada. Sendo assim, diversas arquiteturas e funções de ativação foram consideradas e testadas para os modelos de RNA, escolhendo-se aquela que, no final, melhor otimizou a previsão dos dados. O inverso da perplexidade (IPP) e acurácia foram utilizados como indicador, onde para o IPP uma taxa maior indica uma entropia menor entre os rótulos e as previsões.

3.6 Preenchimento das inspeções

Como discutido em [7], a utilização da periodicidade da inspeção como parâmetro de entrada pode aumentar a complexidade do modelo. Portanto, uma estratégia razoável é eliminá-la como entrada, preenchendo as inspeções vazias no conjunto de dados e tornando constante o intervalo entre as inspeções (1 ano). Diferentes abordagens são discutidas em [7] para alcançar esses resultados desejados. A Figura 8 ilustra o processo de preenchimento. Um total de 4.782 índices de condição foram gerados.



Figura 8. Preenchimento do banco de dados

4. RESULTADOS E PREVISÕES

Nesta seção serão apresentados os resultados dos testes realizados e previsões. As previsões são apresentadas como uma forma de ilustração considerando um horizonte de tempo de 100 anos. Durante este período, nenhuma atividade de manutenção é assumida.

4.1 Arquitetura da rede neural

Para demonstrar a influência da arquitetura, da função de ativação e do modelo estatístico, diferentes configurações foram elaboradas. A Tabela 1 traz um resumo dos resultados para doze configurações distintas. Como pode observar-se, o aumento do número de camadas e neurônios não trouxe um melhoramento significativo para o modelo em termos de desempenho. É possível observar uma diferença nos resultados quando se utiliza como métrica a acurácia e o IPP. Os modelos atingiram uma acurácia de, aproximadamente, 90%, enquanto que, para o caso da IPP, eles atingiram 72% de probabilidade de uma previsão correta. O modelo com 1 camada e 5 neurônios e com função de ativação tangente hiperbólica é então adotado.

Tabela 1. Testes estatísticos das arquiteturas

Arquitetura	Ativação	Acurácia		IPP	
		Treino	Validação	Treino	Validação
5	relu	0.899 (0.006)	0.899 (0.001)	0.717 (0.011)	0.717 (0.003)
	logistic	0.899 (0.006)	0.899 (0.001)	0.718 (0.011)	0.718 (0.003)
	tanh	0.899 (0.006)	0.899 (0.001)	0.718 (0.011)	0.718 (0.003)
3,3	relu	0.822 (0.142)	0.825 (0.140)	0.621 (0.143)	0.626 (0.140)
	logistic	0.899 (0.006)	0.899 (0.001)	0.717 (0.011)	0.716 (0.004)
	tanh	0.899 (0.006)	0.899 (0.001)	0.717 (0.011)	0.717 (0.003)
5,5	relu	0.897 (0.007)	0.897 (0.004)	0.712 (0.015)	0.712 (0.010)
	logistic	0.899 (0.006)	0.899 (0.001)	0.718 (0.011)	0.717 (0.003)
	tanh	0.899 (0.006)	0.899 (0.001)	0.728 (0.011)	0.718 (0.003)
5,5,5	relu	0.899 (0.006)	0.899 (0.001)	0.716 (0.012)	0.716 (0.003)
	logistic	0.897 (0.007)	0.897 (0.004)	0.715 (0.014)	0.714 (0.003)
	tanh	0.899 (0.006)	0.899 (0.001)	0.718 (0.011)	0.718 (0.003)

A Figura 9 (esquerda) mostra a curva média (e o intervalo de confiança) de uma ponte estar em um determinado IC, ao longo do tempo, partindo de um IC inicial igual a 5. É possível observar que a curva, entre o IC igual a 5 e 4, cai significativamente em apenas alguns anos. A média para uma ponte atingir o IC igual a 3 é de 18 anos e o IC igual a 2 de 40 anos. Além disso, é possível observar uma alta dispersão no tempo que a ponte atinge o IC igual a 2, variando de 10 a 90 anos. A Figura 9 (direita) mostra a curva de deterioração para diferentes IC iniciais.

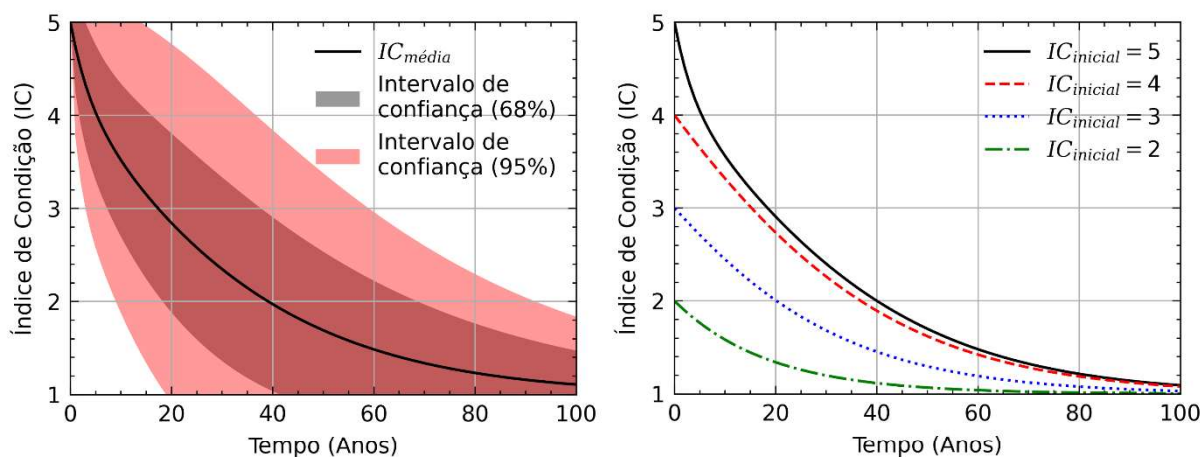


Figura 9. Previsão de deterioração da ponte

4.2 Número de inspeções

Uma pergunta comum na hora de desenvolver um modelo baseado em RNA é o tamanho do banco de dados necessário para se obter um modelo adequado. Dessa forma, para responder essa pergunta e verificar o desempenho do algoritmo em resposta à quantidade de dados, um estudo do tamanho do conjunto de dados de treinamento foi realizado.

Para elaborar tal estudo, o banco de dados utilizado para o treinamento do modelo foi particionado em diferentes tamanhos e os modelos de RNA foram calibrados para os diferentes banco de dados. O processo foi repetido 10 vezes para cada partição do banco de dados. A Figura 10 traz o resultado da dispersão dos resultados em relação ao tamanho do conjunto de dados de treinamento.

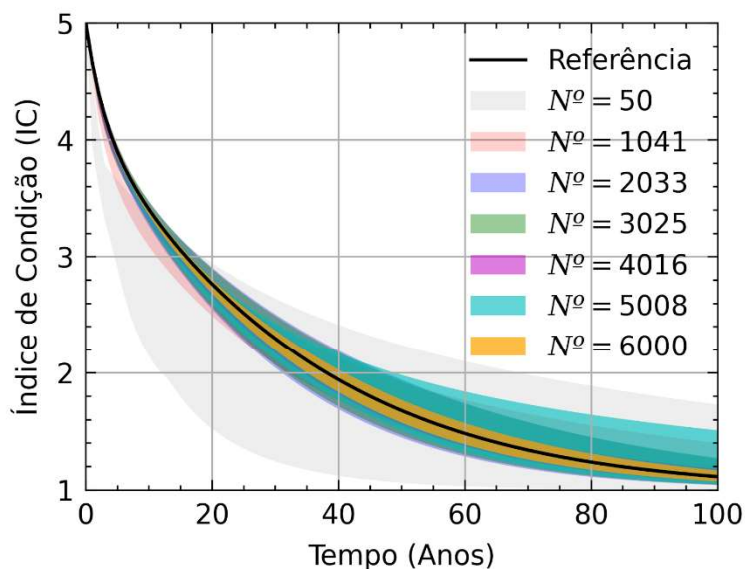


Figura 10. Previsão de deterioração da ponte para diferentes número de inspeções

A partir do gráfico, podemos observar como o tamanho do banco de dados afeta o desempenho do modelo. Podemos concluir, com esse resultado, que o modelo tende a convergir com um número de inspeções acima de 6 mil.

4.3 Variáveis adicionais

Sabendo-se que o processo de deterioração difere em pontes submetidas a diferentes condições, o modelo foi atualizado adicionando novas variáveis (*inputs*), na tentativa de melhorar os resultados. Para o caso de dados categóricos, a codificação distribuída (One-hot encoder) foi utilizada para alimentar o modelo. Um resumo dos resultados é apresentado na Tabela 2. Esses resultados mostram que a adição de novos *inputs* ao modelo ajuda a melhorar seu desempenho.

Tabela 2. Variáveis adicionais

Variável	IPP
Referência	0.727
PIB	0.727
Comprimento	0.733
VMD	0.750
Idade	0.745
Material	0.730
Brooks	0.729

4.3.1 Idade

O ano de construção (ou idade da ponte) foi selecionado para demonstrar o seu desempenho e vida útil. A Figura 11 mostra as curvas de deterioração para diferentes idades. Se o IC igual a 2 for adotado como condição mínima aceitável, a vida útil média prevista de uma ponte com idade de 100 anos e uma recém construída (0 anos) é de 10 e 57 anos, respectivamente. A variação significativa da vida útil da ponte ilustra o impacto considerável da idade no desempenho de uma ponte. Mesmo que uma ponte antiga seja restaurada para um índice de condição igual a 5, a sua deterioração será mais rápida do que a de uma ponte nova.




Figura 11. Curva de degradação de acordo com a idade da ponte

5. CONCLUSÕES

Os atuais BMS fazem uso de modelos de deterioração para análise de priorização de pontes para atividades de manutenção. Devido a isso, vários estudos têm sido realizados para melhorar tais modelos [1-7,12-14]. Seguindo essa atual corrente, este trabalho visou o aprimoramento de modelos de deterioração baseados em RNA.

O presente estudo desenvolveu um modelo preditivo baseado em uma rede neural artificial de classificação multi-classe para a previsão da deterioração de pontes, usando dados históricos de inspeções como fonte primária de informação. Os resultados indicam o potencial de RNA como ferramenta de predição da deterioração. O modelo desenvolvido tem a capacidade de prever com precisão a condição das pontes e, portanto, fornecer informações pertinentes para o planejamento de manutenção e tomada de decisão. Para todos os estudos elaborados neste artigo, o inverso da perplexidade foi utilizado como parâmetro principal para avaliação do desempenho do modelo.

Os resultados discutidos no estudo paramétrico da arquitetura (item 4.1) demonstram que não há necessidade da utilização de arquiteturas complexas. Um modelo com 1 camada e 5 neurônios foi suficiente para atingir resultados satisfatórios.

No estudo da sensibilidade do modelo em relação ao número de inspeções (item 4.2), pode-se perceber que os resultados tendem a convergir quando o número de inspeções se aproxima de 6 mil inspeções. Esses resultados indicam a necessidade de se trabalhar com bancos de dados robustos e reforçam o rigor dos estudos aqui desenvolvidos em virtude de ter como *input* um elevado número de inspeções, 30 mil, aproximadamente.

No item 4.3, discutiu-se a possibilidade de se utilizar outras variáveis como *input* para o modelo. Um resultado mais detalhado foi exposto para o caso da idade da ponte, onde pode concluir-se que pontes com idades mais avançadas tendem a deteriorar com maior velocidade, quando comparado com pontes mais novas. Sendo assim, mesmo que duas pontes

apresentem o mesmo índice de condição, a ponte mais velha irá deteriorar-se mais rapidamente.

Ressalta-se que a aplicação do modelo de previsão de RNA a outros elementos de pontes ou pontes em outros estados, modais ou países pode exigir a redefinição de parâmetros significativos que influenciam a deterioração e a reavaliação do modelo de previsão de RNA.

AGRADECIMENTOS

Os autores agradecem ao Departamento de Infraestrutura de Transportes (DNIT), à Agência Nacional de Transportes Terrestres (ANTT), ao grupo EcoRodovias, Rota das Bandeiras, ViaBahia, Universidade de São Paulo (USP) e Centro Federal de Educação Tecnológica de Minas Gerais (CEFET-MG) pelo apoio à pesquisa e disponibilização dos dados que permitiram a realização deste trabalho.

Este trabalho foi parcialmente financiado pela FCT/MCTES através de fundos nacionais (PIDDAC) no âmbito da Unidade de I&D Instituto para a Sustentabilidade e Inovação em Engenharia Estrutural (ISISE), sob a referência UIDB /04029/2020, e parcialmente financiado pelo programa de pesquisa e inovação Horizonte 2020 da União Europeia, com a referência nº 955337 , e contou com o apoio do programa de capacitação de docentes do Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais (IFMG).

REFERÊNCIAS

- [1] Ilbeigi, M.; Pawar, B.A. – “Probabilistic Model for Optimal Bridge Inspection Interval”, *Infrastructures*, 2020, 5(6), 47. <https://doi.org/10.3390/infrastructures5060047>
- [2] Baron, E.A.; Galvão, N.; Docevska, M.; Matos, J.C.; Markovski, G. – “Application of quality control plan to existing bridges”, *Struct. Infrastruct. Eng.*, 2021, p. 1-17. <https://doi.org/10.1080/15732479.2021.1994618>
- [3] Hadjidemetriou, G.M.; Herrera, M.; Parlikad, A.K. – “Condition and criticality-based predictive maintenance prioritisation for networks of bridges”, *Struct. Infrastruct. Eng.*, 2021, p. 1-16. <https://doi.org/10.1080/15732479.2021.1897146>
- [4] Oliveira, C. – “Determinação e análise de taxas de Deterioração de pontes Rodoviárias do Brasil”, Universidade Federal de Minas Gerais, 2018. <http://hdl.handle.net/1843/41718>
- [5] Gomes, C.; Monteiro, E.; Vítório, A. – “Um estudo sobre a degradação estrutural de pontes e viadutos rodoviários”, XIII Congresso Internacional sobre Patologia e Reabilitação de Estruturas, 2017, p. 67-81.
- [6] Mendes, P. – “Contribuição para um modelo de gestão de pontes de concreto aplicado à rede de rodovias brasileiras”, Universidade de São Paulo, 2009.
- [7] Santos, A. F.; Bonatte, M. S.; Sousa, H. S.; Bittencourt, T. N.; Matos, J. C. – “Improvement of the Inspection Interval of Highway Bridges through Predictive Models of Deterioration”, *Buildings*, 2022, 12(2), p. 1–22. <https://doi.org/10.3390/buildings12020124>
- [8] Santos, A. – “Alguém sabe quantas pontes existem nas rodovias do Brasil?”, 2017. Disponível em: <http://www.guiadotrc.com.br/noticias/noticialD.asp?id=36867> (Acesso em 15 jul. 2022).
- [9] DNIT-010 – “Inspeções em pontes e viadutos de concreto armado e protendido – Procedimento”, 2004

- [10] ABNT NBR 9452:2019 – “Inspeção de pontes, viadutos e passarelas de concreto – Procedimento”
- [11] ARTESP ETC 21-002 – “Controle das Condições Estruturais, Funcionais e de Durabilidade das Obras de Arte Especiais”, 2007
- [12] Bu, G.; Son, J.; Lee, J. et al. – “Typical deterministic and stochastic bridge deterioration modelling incorporating backward prediction model”, *Civil Struct Health Monit*, 2013, 3, p. 141–152. <https://doi.org/10.1007/s13349-013-0044-5>
- [13] Tran, H. – “Sensitivity of Markov Model to Different Sampling Sizes of Condition Data”, *Perform. Constr. Facil.*, 2016, 30, p. 1–5. [https://doi.org/10.1061/\(ASCE\)CF.1943-5509.0000828](https://doi.org/10.1061/(ASCE)CF.1943-5509.0000828)
- [14] Srikanth, I.; Arockiasamy, M. – “Deterioration models for prediction of remaining useful life of timber and concrete bridges: A review”, *Journal of Traffic and Transportation Engineering*, 2020, 7(2), p. 152–173. <https://doi.org/10.1016/j.jtte.2019.09.005>
- [15] Haykin, S. – “Neural Networks and Learning Machines”. Prentice Hall, 2008, 3rd ed.
- [16] Python Software Foundation – “Python Language Reference. Version 3.9”, 2015, Disponível em: <http://www.python.org> (Acesso em 15 jul. 2022).
- [17] Pedregosa, F.; Varoquaux, G.; Gramfort, A. et al. – “Scikit-learn: Machine Learning in Python”, *J. Mach. Learn. Res.*, 2021, 12, p. 2825–2830. <https://doi.org/10.48550/arXiv.1201.0490>
- [18] Jackson, S.L. – “Research Methods and Statistics: A Critical Thinking Approach”, *Cengage Learning*, 2009, 5rd ed.
- [19] Müller, A.C.; Guido, S. – “Introduction to Machine Learning with Python and Scikit-Learn”. O’Reilly Media, 2015, 1st ed.
- [20] MacKay, D.J.; Mac Kay, D.J. – “Information Theory, Inference, and Learning Algorithms”. Cambridge University Press, 2003, 1st ed.