

Desenvolvimento de Modelos Preditivos para Gestão da Manutenção de Obras de Artes Especiais no Brasil

Marianna D. Verduin, Marcos H.F. Ribeiro, José Maria Franco de Carvalho, Flavio Antonio Pereira

ODS9: Indústria, inovação e infraestrutura

Introdução

A manutenção eficiente das infraestruturas de transporte do país é apenas um dos desafios enfrentados quando abordamos a temática de indústria, inovação e infraestrutura do país. Esse projeto, em parceria com o Departamento da Engenharia Civil (DEC) e o Departamento Nacional de Infraestrutura de Transportes (DNIT), visa explorar métodos eficazes para a predição precisa de manutenção de pontes nacionalmente. Dessa forma, é possível encontrar um equilíbrio viável que assegura a segurança e o funcionamento das vias públicas de transporte, porém que aprimora a utilização do recurso público.

Objetivos

O objetivo da pesquisa é investigar e aprimorar métodos preditivos aplicados à manutenção de pontes rodoviárias em âmbito nacional. A pesquisa busca contribuir para a formulação de estratégias mais eficazes e sustentáveis de gestão e de infraestrutura, conciliando critérios de segurança estrutural com responsabilidade fiscal e inovação tecnológica, através dos seguintes objetivos específicos:

- Efetuar o pré-processamento e tratamento do *dataset*;
- Conduzir uma análise multivariada para seleção de variáveis preditoras;
- Empregar técnicas de redes neurais para desenvolvimento do modelo;
- Comparar o desempenho do modelo com resultados obtidos por métodos de outras naturezas;

Metodologia

Inicialmente, foi realizado o pré-processamento do *dataset*, que compreende 515 pontes gerenciadas pelo DNIT (Departamento Nacional de Infraestrutura de Transportes), com a remoção de dados faltantes e a normalização das variáveis numéricas. Na etapa seguinte, procedeu-se com uma análise multivariada, com o objetivo de identificar correlações significativas entre variáveis e uma melhor compreensão das relações entre os fatores. Com base nas variáveis selecionadas, implementou-se um modelo preditivo baseado em Redes Neurais Profundas. Por fim, o modelo foi comparado com resultados obtidos de forma analítica, com base na experiência de especialistas humanos.

Apoio Financeiro

Resultados

A pesquisa buscou confrontar os resultados obtidos por uma Rede Neural profunda contra uma série de métodos analíticos de estimativa da quantidade de serviços de manutenção e reparo. Nestes métodos, informam-se características dos danos sofridos pelas pontes e, para cada tipo de reparo necessário, aplica-se um método estimador diferente. Na abordagem via Rede Neural o tipo de serviço se torna um parâmetro e é passado para o modelo, juntamente com as demais características da ponte. A Figura 1, a seguir, ilustra os métodos analíticos. A Figura 2 ilustra a evolução da função de perda (*Mean Squared Error* - MSE) para o treinamento e avaliação do modelo ao longo de 300 épocas.

Table 6. Parametric models for quantitative maintenance services	
Service	Calculate service quantity
Concrete surface clearing	Cracking/Paving (m ²) = Length (m) x Width (m)
Manual painting	Cracking/Painting (m ²) = Length (m) x Width (m)
Crack injection	Crack injection (kg) = Length (m) x Width (m) x Depth (m) x 1000 x 1.5 (kg/l)
Hydrodemolition	Crack injection (kg) = 0.375 x Length (m)
Controlled demolition	Crack injection (kg) = 0.375 x Length (m)
Plywood forms	Hydrodemolition/Controlled demolition (m ²) = Length (m) x Width (m) x 0.05 (m)
Rebar CA-50	Plywood forms (m ²) = Perimeter (m) x Height (m)
Miscellaneous concrete	Rebar CA-50 (kg) = (100/1000 x 4/4 x 7850) x Length (m) x Quantity (unit)
Dry sprayed concrete	Miscellaneous concrete (m ³) = Length (m) x Width (m) x 0.05 (m)
Concrete Drilling	Concrete Drilling (m) = Quantity (unit) x Extension (m)
Structural adhesive	Structural adhesive (kg) = Rebar Length (m) x 1.06 x 0.002 (kg) x 1.2 (kg/l)

Figura 1. Métodos analíticos de cálculo de quantidade de serviço, a partir das características das pontes (MARTINS, A. C. P., 2025)




Figura 2. Acompanhamento da função de perda (loss) durante o treinamento e avaliação do modelo de redes neurais

Os resultados obtidos pelo modelo baseado em redes neurais foi promissor, atingindo $R^2 = 0.93$ e valores baixos para a MSE.

Conclusões

Os resultados alcançados permitem concluir que é possível se construir um modelo mais generalista para o problema proposto do que um conjunto de regras analíticas propostas por especialistas humanos. O modelo é capaz de aprender não só as relações observadas pelos especialistas, mas também se adaptar automaticamente a cada tipo de situação. No entanto, o modelo foi validado perante a um conjunto reduzido de estruturas (515 pontes) e um estudo mais amplo, envolvendo mais situações, em diferentes cenários poderia colocar mais à prova os promissores resultados.

Como trabalhos futuros, sugere-se a expansão do *dataset* para contemplar mais casos, bem como estudos para reduzir a esparsidade dos dados de entrada, por meio de *embedding* ou outra estratégia que possa aprender representações mais compactas dos dados.

Bibliografia

MARTINS, A. C. P. *Methodologies for damage information modeling in bridge management systems*. 2025. 169 f. Tese (Doutorado em Engenharia Civil) - Universidade Federal de Viçosa, Viçosa, 2025.