

MODELO DE PREVISÃO DA DEFORMAÇÃO PERMANENTE DE FUNDAÇÕES DE VIAS-FÉRREAS COM RECURSO A UMA REDE NEURONAL ARTIFICIAL

Prediction model for permanent deformation of railway subgrade using an artificial neural network

Ana Ramos^a, António Gomes Correia^b, Rui Calçada^a

^a Departamento de Engenharia Civil, Faculdade de Engenharia da Universidade do Porto, Portugal

^b ISISE, Departamento de Engenharia Civil, Escola de Engenharia da Universidade do Minho, Portugal

^c Departamento de Engenharia Civil, Faculdade de Engenharia da Universidade do Porto, Portugal

RESUMO – A previsão da deformação permanente na fundação e respetiva fiabilidade é uma das principais preocupações dos gestores das Infraestruturas Ferroviárias, pois pode influenciar os custos de manutenção da via em serviço. Este artigo propõe uma nova metodologia relativa à previsão da deformação permanente com base num estudo paramétrico realizado usando uma abordagem híbrida e que inclui o desempenho a curto e longo prazo. O estudo realizado permitiu a construção de uma base de dados robusta que foi utilizada neste estudo para prever a deformação permanente. A base de dados alimenta um modelo da rede neuronal, cujo desempenho foi avaliado com base em diferentes métricas: MAE, MSE, RMSE, desvio padrão e coeficiente de regressão. O modelo foi testado e validado com base em resultados experimentais. Os resultados obtidos mostram que o modelo desenvolvido é rápido e eficiente para prever com precisão a deformação permanente induzida pela passagem dos comboios. O modelo tem o potencial para ser implementado num sistema computacional de apoio de decisão para manutenção e gestão de linhas ferroviárias.

ABSTRACT – The prediction of the permanent deformation in the subgrade and its reliability is one of the main concerns of the Railway Infrastructure Managers, as it can influence the reduction of the maintenance costs of the track in service. This study proposes a novel methodology for predicting permanent deformation based on a parametric study performed using a hybrid approach that includes the short and long term performance. The conducted study allowed the construction of a robust database used in this study to forecast the permanent deformation. The database feeds the neural network model, whose performance was evaluated using different metrics: MAE, MSE, RMSE, standard deviation, and regression coefficient. The model was tested and validated based on experimental results. The obtained results demonstrate that the developed model is rapid and efficient in accurately predicting the permanent deformation induced by the passage of trains. The model has the potential to be implemented in a computational decision support system for railway track maintenance and management.

Palavras Chave – Redes neuronais, Deformação permanente, Modelos preditivos, Via férrea.

Keywords – Neural network, Permanent deformation, Predictive models, Railway.

E-mails: aramos@fe.up.pt (A. Ramos), agc@civil.uminho.pt (A. Correia), ruiabc@fe.up.pt (R. Calçada)

ORCID: orcid.org/0000-0002-8381-0126 (A. Ramos), orcid.org/0000-0002-0103-2579 (A. Correia), orcid.org/0000-0002-2375-7685 (R. Calçada)

1 – INTRODUÇÃO

A previsão da deformação permanente tem sido, nos últimos anos, um tópico importante no âmbito da engenharia ferroviária. A degradação da via ao longo dos anos, especialmente na fundação e fundação, é uma real preocupação dos Gestores das Infraestruturas Ferroviárias, devido ao aumento das operações de manutenção e os custos associados (Nielsen e Li, 2018). A procura de novas técnicas de modelação numérica conduz a uma melhor compreensão do desempenho a curto e longo prazo dos sistemas, permitindo explorar o impacto de medidas adequadas para aumentar a confiabilidade das estruturas ferroviárias (Sadri et al., 2018).

A fundação desempenha um papel importante no comportamento da via. Normalmente, esta camada é composta por geomateriais e apresenta dois tipos de deformação quando submetida a cargas cíclicas: as deformações resilientes e permanentes. Esta última tem uma importância crucial no desempenho de longo prazo da subestrutura (Ling et al., 2017, Ramos et al., 2020, Gomes Correia e Ramos, 2022) que pode impactar o comportamento global do sistema.

Este trabalho propõe uma metodologia que permite prever a deformação permanente de uma estrutura ferroviária, considerando fatores importantes, como o tipo de estrutura ferroviária, o comprimento de onda do perfil de irregularidades, a velocidade do comboio (incluindo a sua aproximação à velocidade crítica), as propriedades mecânicas da fundação (módulo resiliente, ângulo de atrito e coesão) e também a posição da análise na direção longitudinal da via (no caso de irregularidades, a resposta da via pode ser dependente da posição escolhida para a análise). Este trabalho é inovador pois reúne a influência de fatores importantes no desempenho das vias, o tipo de estrutura e a inclusão de uma nova metodologia na previsão da deformação permanente usando o algoritmo da rede neuronal, o que permite reduzir abruptamente o tempo de cálculo. A análise e a base de dados são suportados pelos resultados obtidos numericamente usando uma abordagem híbrida constituída pela ferramenta 2.5D FEM-PML e a implementação numérica de um modelo empírico selecionado de deformação permanente (Ramos et al., 2021a). A abordagem 2.5D FEM-PML permite obter as tensões nos elementos finitos, que são usadas como principais *inputs* para prever a deformação permanente.

Existem diversos estudos sobre a previsão do módulo resiliente usado técnicas de *machine learning* (Hanandeh et al., 2020, Pahno et al., 2021, Indraratna et al., 2023), mas há muito poucos estudos sobre a introdução destas metodologias na previsão da deformação permanente. A metodologia apresentada neste artigo é o próximo passo na previsão do desempenho a longo prazo das vias ferroviárias.

2 – AVALIAÇÃO DO DESEMPENHO DA VIA-FÉRREA A CURTO E LONGO PRAZO: MODELAÇÃO NUMÉRICA

A modelação numérica de avaliação do desempenho de uma estrutura ferroviária pode ser dividida com base no comportamento a curto-prazo e o comportamento a longo-prazo.

Nesta análise, o desempenho a curto-prazo dos sistemas ferroviários foi analisado através da abordagem 2.5D FEM-PML. Esta ferramenta numérica apresenta diversas vantagens, uma vez que combina o reduzido esforço computacional com o caráter tridimensional do problema (Yang e Hung, 2001, Sheng et al., 2006, Alves Costa et al., 2010). No entanto, esta abordagem implica duas condições fundamentais: a secção transversal do sistema deve ser invariante na direção longitudinal e a resposta da estrutura deve estar no domínio linear elástico.

A modelação do sistema veículo-via e a sua interação é realizada a partir de modelos subestruturados: o veículo e via são modelados separadamente, mas as restrições de compatibilidade e equilíbrio são impostas e respeitadas entre eles. Mais detalhes sobre esta metodologia podem ser encontrados em Alves Costa et al. (2010). Em relação às fronteiras, para evitar reflexões espúrias, são adicionadas camadas externas: *Perfectly Matched Layers* (PML's). Este método considera implementação de uma camada externa ao domínio de interesse, permitindo a absorção da energia

das ondas que atingem as fronteiras artificiais. Esta metodologia é descrita com maior detalhe no trabalho desenvolvido por Lopes et al. (2014).

Na abordagem 2.5D FEM-PML, o sistema veículo-via (modelado a partir de uma formulação *multibody*, onde apenas o movimento vertical foi simulado) estão acoplados seguindo uma formulação de conformidade A compatibilidade em termos de deslocamentos entre o veículo e a via é definida pela ligação entre ambos os sistemas, e o contacto roda-carril é simulado através de uma rigidez hertziana linearizada. Mais detalhes sobre esta metodologia podem ser encontrados em Alves Costa et al. (2012).

Por outro lado, o comportamento a longo prazo é caracterizado pela acumulação de deformação permanente ao longo dos ciclos de carga que são aplicados na via. Desta forma, a carga cíclica induz a acumulação da deformação permanente, que é muito pequena durante cada ciclo de carga. No entanto, pode levar ao colapso final da estrutura devido à acumulação de milhões de ciclos (Ramos et al., 2020). Na verdade, existem vários métodos para prever a deformação permanente: modelos elastoplásticos, teoria de *shakedown* e modelos empíricos de deformação permanente. Estes últimos são baseados em ensaios laboratoriais, como ensaios triaxiais, cíclicos ou os ensaios de cilindro oco. A partir destes ensaios laboratoriais, os modelos empíricos são desenvolvidos para tentar reproduzir os resultados experimentais considerando os níveis de tensão aplicados e as propriedades físicas do material ensaiado.

O modelo empírico de deformação permanente selecionado neste trabalho para prever o desempenho a longo prazo é baseado no trabalho desenvolvido por Chen et al. (2014) e inclui a influência combinada do estado de tensão inicial (p_{ini} e q_{ini}), o número de ciclos de carga (N), os níveis de tensão induzidos na fundação durante a passagem do comboio (p_{am} e q_{am}) e também a influência do critério de cedência através da inclusão dos parâmetros s e m diretamente relacionados com a coesão e ângulo de atrito, respetivamente.

$$\varepsilon_1^p(N) = \varepsilon_1^{p0} [1 - e^{-BN}] \left(\frac{\sqrt{p_{am}^2 + q_{am}^2}}{p_a} \right)^a \cdot \frac{1}{m \left(1 + \frac{p_{ini}}{p_{am}} \right) + \frac{s}{p_{am}} - \frac{(q_{ini} + q_{am})}{p_{am}}} \quad (1)$$

Onde os parâmetros ε_1^{p0} , B e a correspondem às constantes do material do modelo, e m e s são definidos pelo critério de cedência: $q=s+m.p$.

3 – MODELO PREDITIVO DA DEFORMAÇÃO PERMANENTE USANDO O ALGORITMO DAS REDES NEURONAIS: APLICAÇÃO A UM CASO DE ESTUDO

3.1 – Desenvolvimento da base de dados com base no modelo de elementos finitos

De forma a prever a deformação permanente, foi desenvolvido um modelo com base no algoritmo das redes neurais e considerando uma base de dados robusta.

A base de dados utilizada para implementar a nova metodologia proposta é baseada num estudo paramétrico desenvolvido para avaliar a influência de alguns fatores importantes no desempenho da fundação considerando diferentes sistemas ferroviários. Assim, foram modeladas três estruturas: via balastrada, via em laje (sistem *Rheda*) e via em laje otimizada composta apenas por uma laje de betão (as camadas de suporte foram eliminadas). O modelo numérico de cada estrutura está representado na Figura 1. A via balastrada é constituída pelos carris, palmilhas, travessas, balastro, sub-balastro e fundação. A via em laje (sistema *Rheda*) é composta pelos carris, palmilhas, laje de betão, camada HBL (*hydraulically bonded layer*) e a camada FPL (*frost protection layer*). A via em laje otimizada é semelhante ao sistema *Rheda* exceto no que diz respeito às camadas HBL e FPL, que não são consideradas neste sistema. Os resultados foram analisados no elemento 1 de cada estrutura devido à sua proximidade ao plano de simetria. Esta escolha simplifica a análise dos resultados das tensões. As propriedades dos elementos e detalhes sobre a modelação são descritos

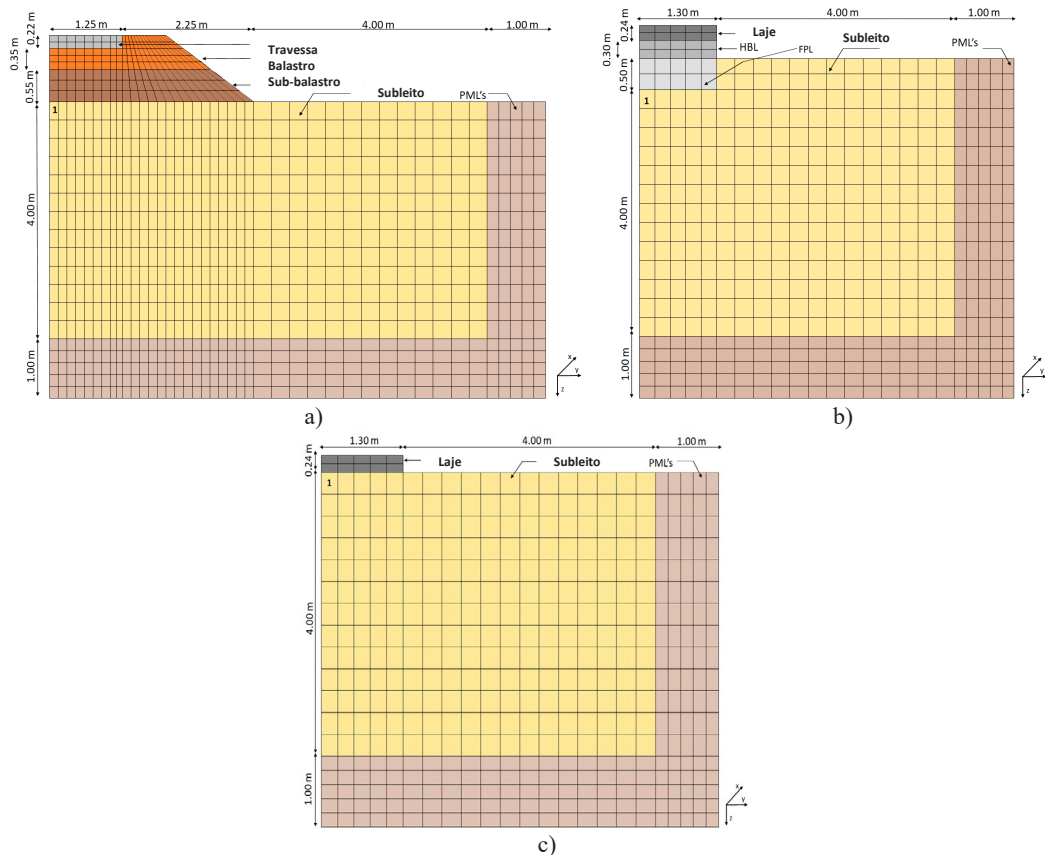


Fig. 1 - Modelos numéricos: a) via balastrada; b) via em laje (sistema Rheda); c) via em laje otimizada apenas com laje de betão (Ramos et al., 2018).

com maior detalhe em Ramos et al. (2021a). É importante referir que foi adotado um estado de tensão isotrópico para ser consistente com os parâmetros de modelação obtidos na literatura relativos aos ensaios triaxiais cíclicos. Tal como representado na Figura 1, o modelo considera as condições de simetria para reduzir o tempo de cálculo.

O veículo adotado neste estudo corresponde ao comboio *Alfa Pendular*. Este comboio é constituído por 6 carruagens e apresenta um plano de simetria. A carga média por eixo é próxima de 135 kN e o comboio foi modelado considerando apenas a massa das rodas.

Para considerar o mecanismo dinâmico, foi gerado artificialmente um perfil de irregularidades considerando um total de 120 frequências. A amplitude do perfil foi definida usando a função de densidade espectral de potência (*PSD*) definida pela Administração Federal de Ferrovias (*FRA*). Esta metodologia é descrita em detalhe no trabalho desenvolvido por Ramos et al. (2021a).

Neste estudo paramétrico foram analisados vários fatores que são designados nesta nova abordagem de variáveis de entrada do modelo. Acrescenta-se ainda que, para todas essas variáveis, foi adotado um intervalo de valores (os valores não foram gerados aleatoriamente, o que significa que foram cuidadosamente selecionados para representar as condições reais observadas) com um valor mínimo e máximo, conforme descrito seguidamente. Desta forma, em primeiro lugar, o tipo de estrutura foi introduzido como uma das variáveis de entrada e inclui as vias balastradas, vias em laje e vias em laje otimizadas. Uma metodologia similar foi aplicada considerando as seguintes variáveis apresentadas no Quadro 1 (Ramos et al., 2021a).

Quadro 1 – Identificação das principais variáveis.

Influência do comprimento de onda do perfil de irregularidades	1< λ <3 (foram adotados os valores recomendados do intervalo D1)	3< λ <25 (designado como D1 em EN13848-5 (2008))	25< λ <70 (designado como D2 em EN13848-5 (2008))	1< λ <70		
Influência da velocidade do comboio	v=80 km/h	v=144 km/h	v=200 km/h	v=300 km/h	v=360 km/h	v=500 km/h
Influência das propriedades mecânicas da fundação	M _r = 90 MPa	M _r =120 MPa	M _r =205 MPa	M _r =280 MPa		
	$\phi=28^\circ, 30^\circ, 35^\circ$ e 40° ; c=0 kPa, 5 kPa e 10 kPa	$\phi=28^\circ, 30^\circ, 35^\circ$ e 40° ; c=0 kPa, 5 kPa e 10 kPa	$\phi=28^\circ, 30^\circ, 35^\circ$ e 40° ; c=0 kPa, 5 kPa e 10 kPa	$\phi=28^\circ, 30^\circ, 35^\circ$ e 40° ; c=0 kPa, 5 kPa e 10 kPa		
Influência da variabilidade espacial do perfil de irregularidades	x=0 m	x=-85.65 m	x=-60.60 m	x=-49.60 m	x=41.4 m	

Com base nos resultados obtidos para cada situação descrita anteriormente no Quadro 1, foram determinadas e incluídas na base de dados as tensões máximas médias e de desvio (q e p , respetivamente). Mais ainda, o número de ciclos de carga e as constantes do modelo relativo ao tipo de material (ε_1^p , B e a) também foram adicionadas à base de dados, uma vez que a deformação permanente depende bastante desses parâmetros.

Desta forma, a base de dados é baseada numa metodologia já implementada que considera a formulação 2.5D FEM-PML com a implementação numérica de um modelo empírico de deformação permanente, combinado o comportamento a curto e longo prazo. De forma sucinta, para prever a deformação permanente, é importante obter as tensões nos elementos finitos selecionados. Estas tensões são determinadas através da formulação 2.5D FEM-PML que permite considerar os mecanismos estáticos e dinâmicos. A partir do valor das tensões em todas as direções, são determinadas as tensões principais, bem como as tensões médias e de desvio, que são entradas principais do modelo empírico de deformação permanente. A partir dessas tensões, é possível prever a deformação permanente. Nesta fase, o critério de cedência, bem como os parâmetros de resistência, como a coesão e ângulo de atrito, também apresentam um papel relevante e, por isso, são também incluídos como variáveis de entrada.

Para cada análise (observação), o modelo 2.5D e o modelo empírico de deformação permanente são executados. Os valores de cada variável são registados, bem como a deformação permanente induzida, que é automaticamente adicionada à base de dados definida no software *MATLAB*. O valor da deformação permanente é apresentado sob a forma de percentagem. O número total de observações é de 186 000. Mais detalhes sobre a construção da base de dados e as variáveis incluídas são fornecidos posteriormente na Secção 3. A base de dados foi posteriormente importada para o software *R* de forma a construir o modelo com base no algoritmo de redes neuronais.

Desta forma, a base de dados é caracterizada por 17 variáveis independentes e a variável alvo que corresponde à deformação permanente. Duas variáveis são classificadas como variáveis categóricas: “tipo de estrutura” e “intervalo de comprimento de onda”. Como este é um problema de regressão, essas variáveis categóricas necessitam de um pré-processamento pois não podem

entrar diretamente no modelo. Assim, as variáveis originais foram recodificadas a partir de um processo designado de "codificação de variáveis dummy". Portanto, a variável "tipo de estrutura" continha três níveis diferentes (via balastrada, via em laje e via em laje otimizada) e a variável "intervalo de comprimento de onda" continha quatro níveis diferentes: $1 < \lambda < 3$, $3 < \lambda < 25$, $25 < \lambda < 70$ e $1 < \lambda < 70$. Logo, a variável "tipo de estrutura" foi recodificada num conjunto de variáveis dummy (cada uma com dois níveis): "via balastrada" e "via em laje otimizada". Uma vez que os resultados associados à via balastrada são semelhantes à via em laje ao nível da fundação, o nível "via em laje" não foi codificado. Nesse caso, foi selecionada a variável mais diferenciadora. A mesma metodologia foi aplicada à variável categórica "intervalo de comprimento de onda". Neste caso, foram criadas 3 variáveis dummy: $1 < \lambda < 3$, $3 < \lambda < 25$ e $25 < \lambda < 70$. A variável $1 < \lambda < 70$ não foi codificada arbitrariamente.

A lista final das variáveis consideradas neste estudo está descrita no Quadro 2. O software R foi utilizado para realizar a previsão da deformação permanente.

Quadro 2 – Lista final das variáveis incluídas.

Código	Nome	Abreviatura
x1	vias balastradas	v. bal
x2	vias em laje otimizadas	V laj. Op.
x3	$1 < \lambda < 3$	$1 < \lambda < 3$
x4	$3 < \lambda < 25$	$3 < \lambda < 25$
x5	$25 < \lambda < 70$	$25 < \lambda < 70$
x6	posição	P
x7	Módulo Resiliente da fundação	M_r
x8	coesão da fundação	c
x9	ângulo de atrito da fundação	ϕ
x10	velocidade do comboio	V
x11	tensão de desvio máxima	q_{max}
x12	tensão média máxima	p_{max}
x13	número de ciclos de carga	N
x14	constante do material: ε_1^{p0}	ε_1^{p0}
x15	constante do material: B	B
x16	constante do material: a	a
x17	deformação permanente	ε_1^p

Uma vez que a base de dados foi preenchida automaticamente e de forma controlada de acordo com as variáveis selecionadas, não existem valores em falta ou observações sem dados. O número total de observações é de 186 000 e o conjunto de dados foi dividido em treino e teste.

Relativamente ao desempenho e à precisão do modelo desenvolvido, esses aspetos são altamente afetados pelas características da base de dados, distribuição das variáveis, escalas dos dados e a correlação entre as variáveis de entrada e de saída. Neste sentido, a caracterização dos dados (análises uni variadas e multivariadas) é muito importante e deve ser realizada na etapa de pré-processamento antes do desenvolvimento/treino do modelo. Neste caso, os resultados da análise multivariada indicaram uma relação linear entre dois atributos. Para o conjunto de dados em análise, o correlograma apresentou correlações lineares muito baixas entre as variáveis com algumas exceções como "Módulo Resiliente" e o "ângulo de atrito", o que é compreensível. Isto significa que uma destas variáveis deve ser excluída do modelo para prever a deformação permanente. Assim, a variável "ângulo de atrito" foi eliminada.

3.2 – Redes neuronais: algoritmo

As técnicas de redes neuronais são uma ferramenta poderosa para resolver problemas com diferentes características pois apresentam poucas limitações e são capazes de estabelecer relações complexas lineares e não lineares entre variáveis dependentes e independentes num pequeno intervalo do tempo (Rezaei-Tarahomi et al., 2017, Ghorbani et al., 2021, Tinoco et al., 2019). No campo da engenharia, é possível encontrar várias aplicações deste tipo de análise, como o estudo das propriedades físicas e mecânicas de colunas de jet grouting (Tinoco et al., 2014, Tinoco et al., 2018).

O algoritmo das redes neuronais em particular é flexível e pode ser aplicado a problemas de classificação ou regressão. A rede neuronal é constituída pelas camadas de entrada, camadas ocultas e camadas de saída. As camadas ocultas (*hidden layers*) utilizam o algoritmo de retropropagação para otimizar os pesos das variáveis de entrada e melhorar a precisão das previsões. As unidades de entrada e saída são designadas de neurónios, que estão interconectados. Cada conexão/ligação possui um peso associado.

Para aplicar este algoritmo é recomendada a normalização dos dados para melhorar a velocidade de construção do modelo. Mais ainda, a normalização permite diminuir a probabilidade de o modelo ficar preso em mínimos locais, facilitando também interpretação dos resultados. No entanto, é importante mencionar que a escala deve ser realizada após a divisão dos dados em treino e teste.

Outro fator relevante da rede neuronal é a seleção do número de neurónios a serem incluídos nas camadas de entrada e ocultas. De facto, não existe uma regra específica para escolher o número correto de neurónios. De forma a encontrar o número otimizado, devem ser realizados vários testes de forma a selecionar a opção que conduz a um melhor modelo preditivo. Ainda assim, existem algumas recomendações. É recomendado, por exemplo, que o número de neurónios esteja entre o tamanho da camada de entrada e o tamanho da camada de saída, sendo geralmente 2/3 do tamanho de entrada. Quando a rede neuronal é treinada, o próprio modelo realiza um gradiente descendente para encontrar coeficientes que se ajustem aos dados de forma a encontrar os pesos ótimos para o modelo.

4 – RESULTADOS E DISCUSSÃO

4.1 – Desenvolvimento do modelo e avaliação

Neste primeiro estudo, todas as variáveis foram incluídas (exceto o “ângulo de atrito, devido à alta correlação com o “Módulo Resiliente”, uma vez que no estudo paramétrico o Módulo resiliente foi definido com base na relação entre esta variável, a velocidades das ondas s , v_s , e os valores típicos de N_{SPT} (Sykora, 1987); o ângulo de atrito foi definido com base na expressão $\phi' = [15.4(N_1)_{60}]^{0.5} + 20^\circ$, que é também dependente do N_{SPT}). Os principais parâmetros que influenciam o modelo foram otimizados para obter um melhor desempenho. Por exemplo, o número das camadas ocultas, neurónios e também o tipo de função de transferência foram cuidadosamente selecionados.

Nos problemas de redes neuronais, a base de dados é dividida em treino, validação e teste. A partir do treino, o modelo tem oportunidade de ver e aprender com os dados. A validação é usada para avaliar o modelo. Desta forma, os dados são usados para ajustar os hiper-parâmetros do modelo. Na fase de teste, o modelo é avaliado, e esta fase é apenas iniciada quando o modelo está completamente treinado.

De forma obter uma melhor precisão das previsões, em primeiro lugar, o conjunto de dados foi dividido em treino e teste. Seguidamente, o conjunto de teste foi mantido separadamente e uma percentagem aleatória de X% do conjunto de treino é escolhida para ser o conjunto de treino real e o restante (100-X%) para ser o conjunto de validação, onde X% é um número fixo. Assim, o modelo é treinado e validado iterativamente nesses diferentes conjuntos. Uma forma de aplicar esta

metodologia é usar a validação cruzada (*cross-validation*). Esta metodologia foi implementada neste estudo, onde o conjunto de treino foi usado para gerar várias divisões dos conjuntos de treino e validação. Esta metodologia evita o problema de *overfitting*. Neste trabalho em específico, foi selecionada a validação cruzada com *k-fold* (*k-fold cross-validation*). Esta abordagem divide o conjunto de dados em *k* subconjuntos diferentes. Assim, *k-1* subconjuntos são usados para treinar e o modelo e o subconjunto restante é usado como conjunto de validação. Os dados são divididos aleatoriamente. Neste caso, foi adotado um valor de *k* igual a 10.

A precisão das previsões foi realizada a partir dos valores obtidos em termos de coeficiente de regressão (*R*), desvio padrão e os erros *MAE*, *MSE* e *RMSE*.

A Rede Neuronal é um algoritmo bastante complexo e muitas vezes designado como algoritmo de “caixa preta”. O algoritmo é sensível ao número de execução das análises e treino. Com base nisto, o modelo foi testado várias vezes pois trata-se da melhor forma de encontrar os parâmetros que melhor se ajustam ao modelo. Mais ainda, o número de camadas ocultas também foi testado. Os dados foram normalizados previamente. O modelo da rede neuronal considerando a presente base de dados está representada na Figura 2. Analisando a Figura 2, é possível identificar 15 variáveis de entrada e uma variável de saída que corresponde à deformação permanente induzida pela passagem do comboio (variável *x17*). Os principais parâmetros que afetam o desenvolvimento do modelo são o número de camadas ocultas, número de neurónios e o tipo de função de transferência. Neste caso, foram consideradas duas camadas ocultas com 10 e 2 neurónios, respetivamente.

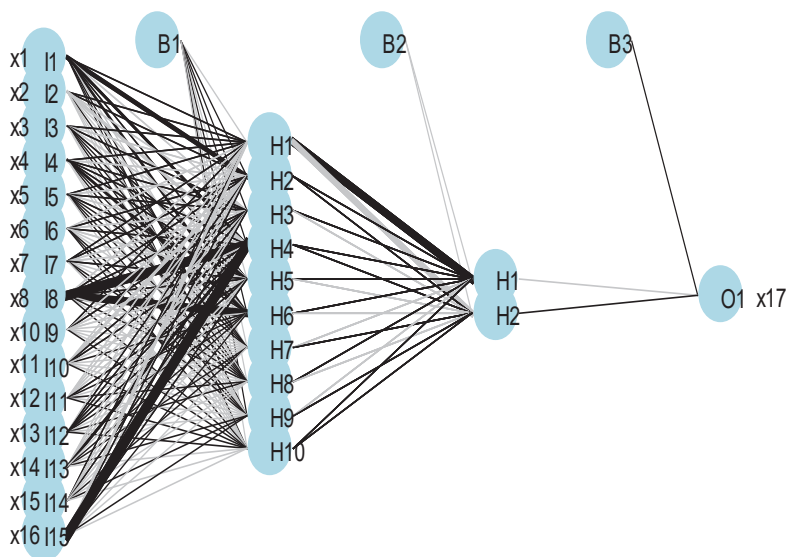


Fig. 2. Modelo desenvolvido utilizando o algoritmo da rede neuronal.

Os resultados das métricas são apresentados no Quadro 3. Ao conjunto de métricas estabelecido ainda foram adicionados os valores máximos e mínimos previstos e observados. O gráfico de dispersão obtido está representado na Figura 3 e ilustra a relação entre os valores previstos e observados relativos à deformação permanente (em percentagem). Os pontos estão distribuídos junto à linha diagonal, o que indica um bom ajuste entre os valores previstos e observados. Mais ainda, a proximidade dos pontos em relação à diagonal confirma a precisão e eficácia do modelo desenvolvido usando o algoritmo das redes neuronais. É possível ainda evidenciar a proximidade entre os valores máximos e mínimos previstos e observados.

Os resultados mostram que os valores reduzidos do desvio padrão, RMSE, MAE e MSE indicam que as previsões do modelo estão consistentemente próximas dos valores reais, com erros mínimos. O coeficiente R próximo de 0.99 sugere uma forte correlação entre os valores previstos e observados. Desta forma, é possível afirmar que o modelo desenvolvido é capaz de prever com precisão a deformação permanente induzida pela passagem do comboio.

Quadro 3 – Avaliação do modelo da rede neuronal: resultados das métricas para o modelo desenvolvido.

Métricas	Resultados
R – Coeficiente de regressão	0.999
Desvio padrão	0.570
RMSE	0.0043
MAE	0.0027
MSE	1.826e-05
Valor máximo previsto	0.00148
Valor mínimo previsto	2.4525
Valor mínimo observado	0.00222
Valor máximo observado	2.4594

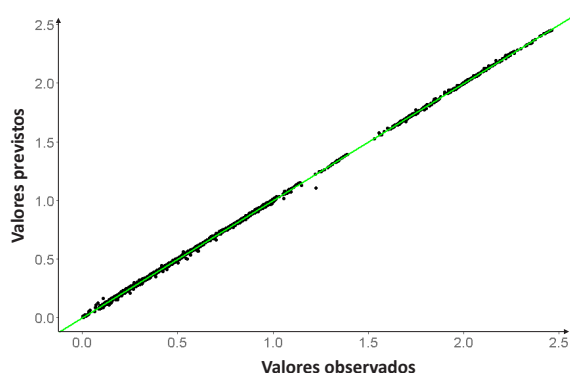


Fig. 3 – Gráfico de dispersão: valores previstos versus valores observados das deformação permanentes, em percentagem.

4.2 – Avaliação da importância das variáveis e correspondência com o conhecimento empírico

De forma a compreender melhor o modelo e a sua estrutura, foi realizada uma nova análise, neste caso de sensibilidade, para entender quais são as variáveis que têm mais impacto ou influência no modelo desenvolvido e qual o nível de correspondência com o conhecimento empírico.

De facto, os pesos que ligam as variáveis numa rede neuronal são semelhantes ou parcialmente análogos aos coeficientes de parâmetros de um modelo de regressão tipo ou padrão e podem ser usados para descrever as relações entre as variáveis. Isto significa que os pesos comandam a influência relativa das informações processadas na rede, de modo que as variáveis de entrada que não são relevantes na sua correlação com a variável de saída ou de resposta são suprimidas pelos pesos. Por outro lado, verifica-se o efeito oposto quando os pesos atribuídos às variáveis explicativas ou importantes têm uma forte relação com a variável de resposta.

A determinação da importância relativa das variáveis explicativas numa rede neuronal supervisionada é baseada no trabalho desenvolvido por Garson (1991). Desta forma, a importância de uma variável explicativa específica relativamente à variável de resposta pode ser determinada

identificando todas as conexões ponderadas entre os nós de interesse. Ou seja, são identificados todos os pesos que ligam o nó de entrada específico que passa pela camada oculta até à variável de resposta específica. Este processo é repetido para todas as outras variáveis explicativas até que se encontre uma lista de todos os pesos que são específicos para cada variável de entrada. Um único valor é obtido para cada variável explicativa que descreve a relação com a variável de resposta do modelo. No entanto, este algoritmo só funciona para redes neuronais com uma camada oculta e uma variável de resposta. No modelo desenvolvido, foram adotadas 2 camadas ocultas. Assim, de forma a ultrapassar este problema, foi adotado o método desenvolvido por Olden et al. (2004). Este método é semelhante ao de Garson pois são utilizados os pesos de ligação entre as camadas da rede neuronal para determinar a importância das variáveis. No entanto, Olden et al. (2004) descrevem um algoritmo de pesos de ligação que supera consistentemente o algoritmo de Garson na representação da verdadeira importância das variáveis em conjuntos de dados simulados. Desta forma, o método de “Olden” calcula a importância das variáveis como o “produto dos” “pelos de ligação” brutos de entrada-oculta e oculta-saída entre cada neurónio de entrada e saída e soma o produto em todos os neurónios ocultos. Uma das vantagens desta abordagem diz respeito às contribuições relativas de cada peso de ligação, que são mantidas em termos de magnitude e sinal, com comparação com o algoritmo de Garson, que considera apenas a magnitude absoluta. Assim, considerando o modelo desenvolvido neste estudo e apresentado nos capítulos anteriores, foram obtidas as variáveis explicativas. O resultado é apresentado na Figura 4.

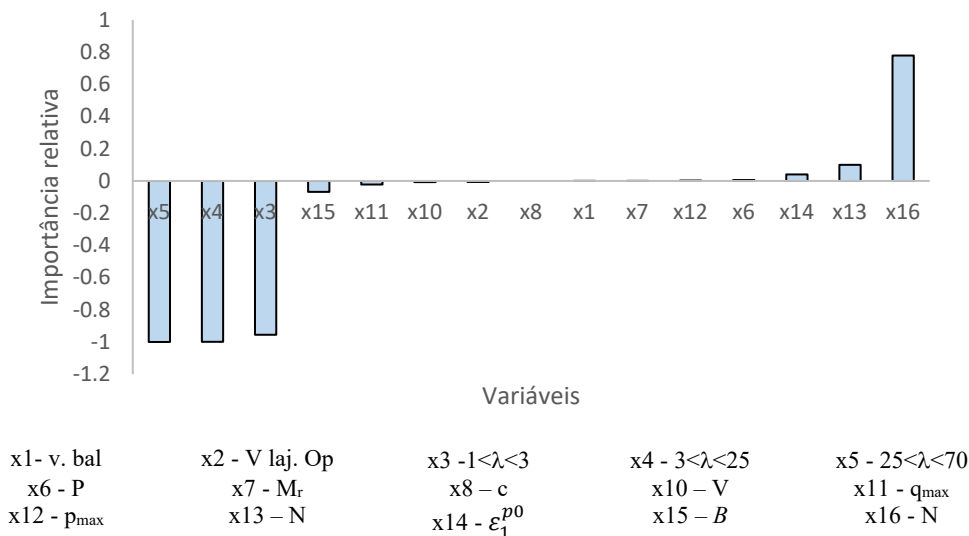


Fig. 4 – Variáveis explicativas do modelo: importância relativa das variáveis.

Os resultados obtidos mostram que as variáveis “x3 - $-1 < \lambda < 3$ ”, “x4 - $3 < \lambda < 25$ ”, “x5 - $25 < \lambda < 70$ ”, “x15 - ε_1^{p0} ” e “x11 - tensão de desvio máxima” apresentam as relações negativas mais fortes com a variável de resposta. Por outro lado, as variáveis “x13 - B”, “x14 - α ” e “x16 - N (número de ciclos de carga)”, apresentam as relações positivas mais fortes com a variável de resposta. Acrescenta-se ainda que as variáveis que têm uma importância relativa próxima de zero (como a “x1 - via balastrada” ou “x7- Módulo Resiliente da fundação”), não têm uma importância significativa ou influência na deformação permanente. Assim, é possível afirmar que, de acordo com esses resultados, esses valores indicam importância relativa próxima de zero, o que significa que estas variáveis têm efeito marginal/residual na deformação permanente.

Apesar da importância dos resultados obtidos anteriormente relativos às variáveis explicativas, é importante comparar com o conhecimento empírico acerca do desenvolvimento da deformação permanente descrito na bibliografia. Assim, os resultados numéricos e os resultados obtidos em ensaios triaxiais cíclicos sugerem que as constantes do modelo empírico, assim como, o número de ciclos de carga também possa ter uma influência significativa na deformação permanente. Os resultados numéricos mostram ainda que a velocidade do comboio também é uma variável importante pois tem uma influência preponderante na amplificação das tensões e respetivos deslocamentos/deformações permanentes. Provavelmente até mais que o comprimento de onda das irregularidades. Isto significa que é necessário refinar o modelo. Neste seguimento, foi realizada uma análise adicional em que foram apenas selecionadas as variáveis explicativas: "x3", "x4", "x5", "x10", "x11", "x13", "x14", "x15" e "x16". A partir deste modelo, foi determinado o erro RMSE, bem como a importância das variáveis. Os resultados obtidos são apresentados na Figura 5. Relativamente ao RMSE, foi obtido um valor bastante mais elevado quando comparado com o modelo com todas as variáveis incluídas: 0.25 versus 0.0043. Isto significa que o modelo precisa de todas variáveis incluídas para determinar, com precisão, a deformação permanente, mesmo as variáveis que apresentem, aparentemente, um efeito residual. Quanto à análise da importância das variáveis, os resultados mostram que este modelo é extremamente dependente da tensão de desvio máxima (x11)

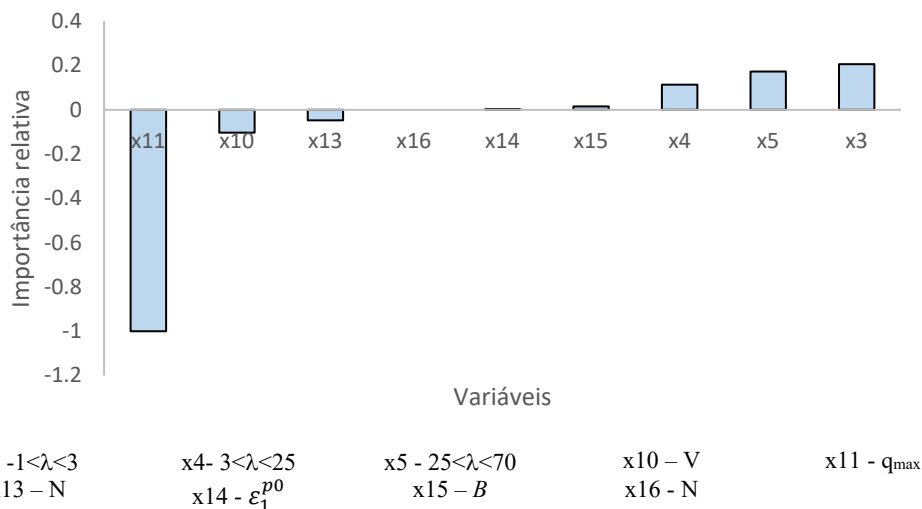
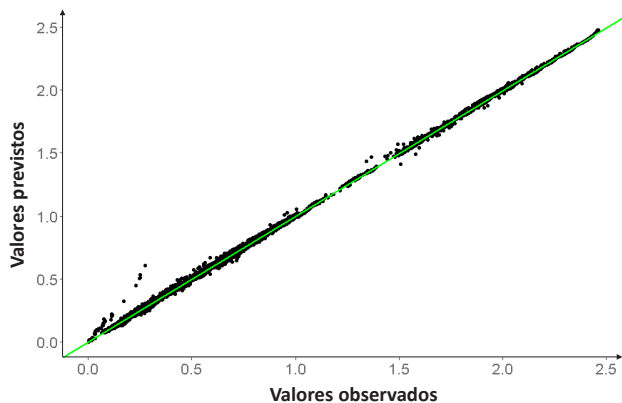


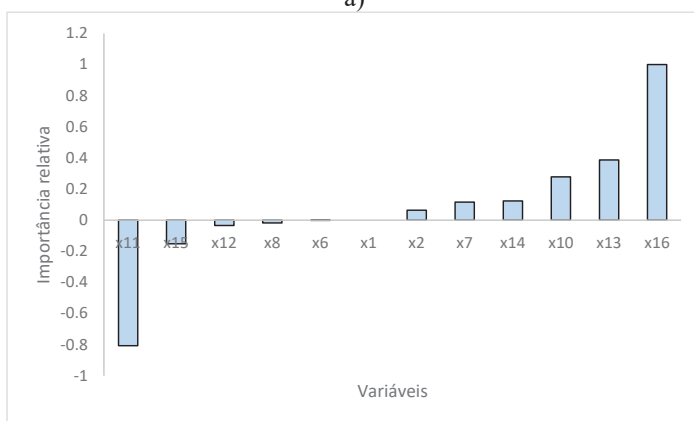
Fig. 5 - Variáveis explicativas do modelo: importância relativa das variáveis considerando um modelo simplificado.

Adicionalmente, foi realizada uma nova análise para avaliar o impacto das variáveis x3, x4 e x5 (relacionadas com a influência do comprimento de onda das irregularidades) na previsão da deformação permanente. Estas variáveis foram removidas da base de dados. Os resultados obtidos são apresentados na Figura 6. Neste caso, o erro RMSE é igual a 0.0073, que é muito próximo do valor obtido inicialmente considerando todas as variáveis incluídas (RMSE=0.0043). Estes resultados estão refletidos no gráfico de dispersão apresentado na Figura 6 a). É importante referir que os existe alguma dispersão e conseqüente afastamento de alguns pontos da diagonal $y=x$ no intervalo $0.0 < x < 0.5$. Estes pontos (menos de 6) correspondem a uma situação muito particular do problema e mostram que o modelo não tem capacidade para capturar e reproduzir corretamente os resultados quando o número de ciclos de carga é igual a 1 ($x_{16}=1$), a estrutura é uma via em laje otimizada ($x_2=1$) e o módulo resiliente é igual a 120 MPa ($x_7=120$). Relativamente à análise da

importância das variáveis, o modelo indica que é extremamente dependente do número de ciclos de carga (x16), tensão de desvio máxima (x11), seguido pelas constantes do material (x13, x14 e x15) e pela velocidade do comboio (x10). O módulo resiliente (x7) e o tipo de estrutura (via em laje otimizada) também são consideradas variáveis importantes. Assim, este modelo e as conclusões obtidas estão alinhadas com o conhecimento adquirido do ponto de vista numérico e empírico apresentado na bibliografia em termos de variáveis explicativas, apesar do aumento muito residual do RMSE.



a)



b)

x1 - v. bal	x2 - V laj. Op	x6 - P	x7 - M_r	x8 - c	x10 - V
x11 - q_{max}	x12 - p_{max}	x13 - N	x14 - ϵ_1^{p0}	x15 - B	x16 - N

Fig. 6 – Resultados com as variáveis pré-selecionadas: a) Gráfico de dispersão: valores previstos versus valores observados das deformação permanentes, em percentagem; b) Variáveis explicativas do modelo: importância relativa das variáveis.

4.3 – Validação experimental dos resultados

De forma a demonstrar a capacidade do modelo desenvolvido e a sua aplicação na previsão da deformação permanente, foi desenvolvida uma nova base de dados, com as mesmas variáveis e cujos valores foram obtidos a partir de resultados experimentais. Desta forma, foram realizados ensaios em laboratório considerando um modelo físico à escala real para simular o desempenho a curto e longo prazo das vias férreas (via balastrada e uma via em laje com 2,2 m de comprimento) utilizando

o dispositivo GRAFT2 (Ramos et al., 2021b). Nestes testes, as estruturas ferroviárias foram submetidas a mais de 3 milhões de ciclos de carga e os deslocamentos permanentes foram medidos ao longo dos testes na fundação das estruturas. Mais ainda, os materiais da subestrutura foram caracterizados em laboratório de forma a determinar o ângulo de atrito, coesão e Módulo Resiliente. Estes testes simularam a passagem do comboio com uma velocidade de 360 km/h usando um método que permitia o carregamento por fases. A deformação permanente induzida na subestrutura foi obtida a partir da medição dos deslocamentos medidos nos transdutores LVDTs colocados em determinadas posições da via.

A partir dos resultados experimentais foram desenvolvidos dois modelos numéricos 3D capazes de reproduzir numericamente os ensaios experimentais. Estes modelos foram posteriormente calibrados a partir do ajuste dos deslocamentos medidos. A este processo designou-se de calibração a curto-prazo. A partir da calibração do modelo, foram obtidas as tensões numéricas em todos os elementos da via. Posteriormente, o modelo empírico de deformação permanente e as respetivas constantes do material (ϵ_1^p , B e a) foram também calibrados a partir do ajuste da curva de deslocamento permanente acumulado. Esta calibração foi designada de calibração a longo-prazo. É importante mencionar que neste estudo não foi incluída a influência das irregularidades da via. Contudo, estudos realizados anteriormente (Ramos et al., 2021a) mostram os comprimentos de onda entre 25 m e 70 m, ou até mesmo entre 3 m e 25 m não influenciam a resposta da via, o que significa que a resposta quasi-estática é praticamente igual à resposta dinâmica (Ramos et al., 2021a). Isto significa que, para esta validação, foi selecionado um comprimento de onda no intervalo entre 25 e 70 m. Além disso, a posição da análise também foi selecionada arbitrariamente devido à ausência do perfil de irregularidades. Seguidamente, os resultados relativos à análise de sensibilidade mostram que este parâmetro tem pouca relevância na deformação permanente.

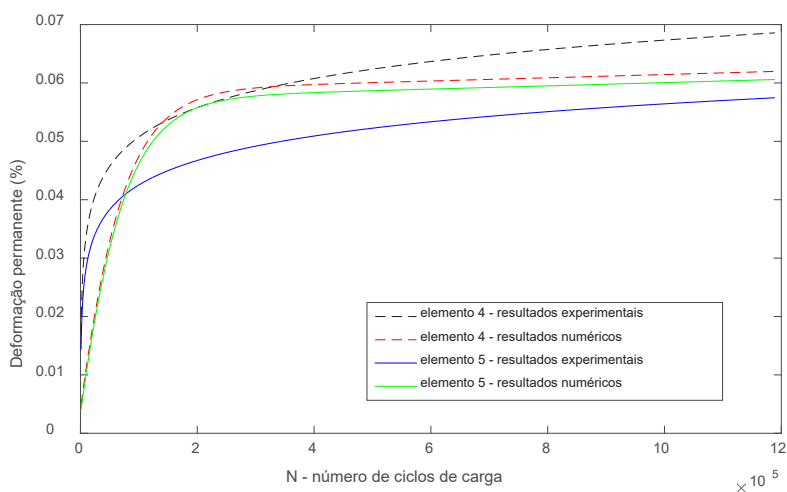
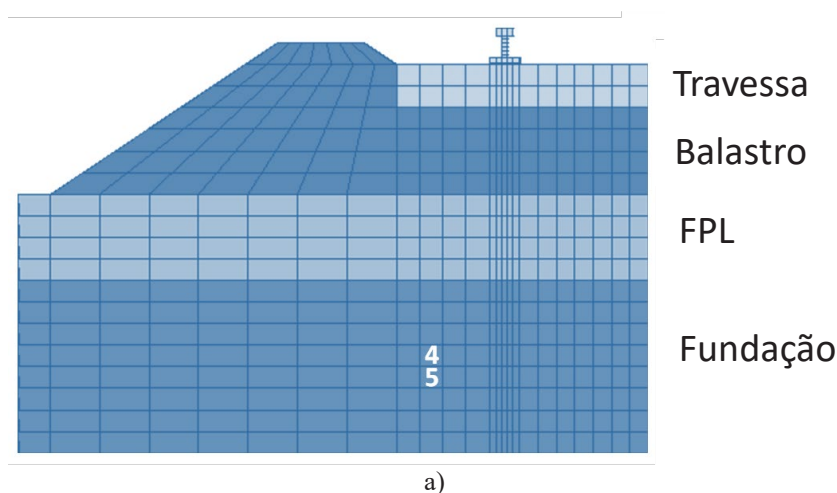
A partir da nova base de dados, são comparadas as deformações previstas e observadas nos elementos selecionados da subestrutura identificados na Figura 7. Os resultados mostram um ajuste satisfatório entre os valores observados (a partir do modelo físico à escala real) e os valores previstos (aplicando o algoritmo da rede neuronal), o que significa que este modelo pode ser utilizado para prever o desenvolvimento da deformação permanente com o número de ciclos de carga. A principal diferença reside no início da estabilização da deformação permanente quando N está entre 10000 e 20000. No entanto, o valor máximo da deformação permanente (após 1 milhão de ciclos de carga) é muito semelhante em ambos os elementos da subestrutura.

5 – CONSIDERAÇÕES FINAIS

O desempenho a longo prazo da fundação em vias balastrada ou em laje é de extrema importância pois pode influenciar o comportamento global da via, assim como o número de operações de manutenção (e custos associados). Este estudo apresenta uma nova e inovadora metodologia capaz de prever a deformação permanente com recurso a redes neurais artificiais.

A base de dados foi construída considerando resultados obtidos a partir de modelação numérica usando uma abordagem híbrida que combina a ferramenta numérica 2.5D FEM-PML e a implementação de um modelo empírico de deformação permanente. Com base nesta metodologia, foi realizado um estudo paramétrico para compreender os fatores que podem influenciar o desenvolvimento da deformação permanente da fundação considerando diferentes estruturas ferroviárias: via em laje (sistema *Rheda*), via balastrada e via em laje otimizada. Os resultados foram analisados em detalhe, comparados, avaliados e registados numa base de dados. Acrescenta-se ainda que o mecanismo dinâmico também foi incluído através da geração de um perfil de irregularidades.

A partir da base de dados, foi implementado um algoritmo da rede neuronal para construir um modelo de previsão da deformação permanente. A precisão do modelo foi avaliada considerando diferentes métricas como o coeficiente de regressão R , o desvio padrão e os erros RMSE, MAE e MSE. Os valores reduzidos das diferentes métricas mostram que a rede neuronal conduz a resultados muito satisfatórios na previsão da deformação permanente.



b)

Fig. 7 – Validação do modelo com base em resultados experimentais: a) identificação dos elementos da subestrutura; b) deformação permanente, em percentagem, dos elementos 4 e 5 da subestrutura da via balastrada.

Foram ainda determinadas as variáveis explicativas do modelo e estas foram comparadas em relação ao conhecimento numérico e empírico existente na bibliografia. Os resultados mostram que, embora o comprimento de onda tenha uma influência significativa na deformação permanente, há outras variáveis igualmente importantes. Posteriormente as variáveis relativas ao comprimento de onda foram excluídas da base de dados, o que resultou num aumento muito residual do RMSE e um bom desempenho do modelo. Os resultados obtidos mostraram que as variáveis explicativas identificadas nesta nova análise estão alinhadas com as conclusões numéricas e empíricas descritas na bibliografia especializada.

Mais ainda, o modelo foi validado com base em resultados experimentais obtidos num modelo físico da via balastrada à escala real com uma capacidade preditiva muito satisfatória.

Estas descobertas destacam a potencial aplicação do modelo desenvolvido em cenários práticos para auxiliar na manutenção e gestão de vias-férreas, oferecendo um suporte eficiente e confiável de apoio à tomada de decisão. Desta forma, com esta metodologia inovadora é possível prever a

deformação permanente com alta precisão e eficiência, numa fração de tempo muito inferior aos métodos tradicionais.

6 – AGRADECIMENTOS

Este trabalho foi parcialmente realizado no âmbito do In2Track3, um projeto de investigação do Shift2Rail. Este trabalho foi também parcialmente financiado pela FCT/MCTES através de fundos nacionais (PIDDAC) no âmbito da Unidade de I&D *Institute for Sustainability and Innovation in Structural Engineering* (ISISE), sob a referência UIDB/04029/2020. Adicionalmente, contou com o apoio financeiro de Base Funding - UIDB/04708/2020 do CONSTRUCT - Instituto de I&D em Estruturas e Construções - financiado por fundos nacionais através do FCT/MCTES (PIDDAC).

7 – REFERÊNCIAS BIBLIOGRÁFICAS

- Alves Costa, P.; Calçada, R.; Silva Cardoso, A. (2012). *Track-ground vibrations induced by railway traffic: In-situ measurements and validation of a 2.5D FEM-BEM model*. Soil Dynamics and Earthquake Engineering, vol. 32, pp. 111-128. <https://doi.org/10.1016/j.soildyn.2011.09.002>.
- Alves Costa, P.; Calçada, R.; Silva Cardoso, A.; Bodare, A. (2010). *Influence of soil non-linearity on the dynamic response of high-speed railway tracks*. Soil Dynamics and Earthquake Engineering, vol. 30, pp. 221-235. <https://doi.org/10.1016/j.soildyn.2009.11.002>.
- Chen, R.; Chen, J.; Zhao, X.; Bian, X.; Chen, Y. (2014). *Cumulative settlement of track subgrade in high-speed railway under varying water levels*. International Journal of Rail Transportation, vol. 2, pp. 205–220. <https://doi.org/10.1080/23248378.2014.959083>.
- EN13848-5 (2008). *Railway Applications - Track - Track geometry quality - Part 5: Geometric quality levels*. EN13848. European Committee for Standardization (CEN), Brussels, Belgium.
- Garson, G. D. (1991). *Interpreting neural network connection weights*. Artificial Intelligence Expert, vol 6, pp. 46–51.
- Ghorbani, B.; Arulrajah, A.; Narsilio, G.; Horpibulsuk, S.; Bo, M. W. (2021). *Shakedown analysis of PET blends with demolition waste as pavement base/subbase materials using experimental and neural network methods*. Transportation Geotechnics, vol.. 27. <https://doi.org/10.1016/j.trgeo.2020.100481>.
- Gomes Correia, A.; Ramos, A. (2022). *A geomechanics classification for the rating of railroad subgrade performance*. Railway Engineering Science, vol. 30, pp. 323-359. <https://doi.org/10.1007/s40534-021-00260-z>.
- Hanandeh, S.; Ardah, A.; Abu-Farsakh, M. (2020). *Using artificial neural network and genetics algorithm to estimate the resilient modulus for stabilized subgrade and propose new empirical formula*. Transportation Geotechnics, vol. 24. <https://doi.org/10.1016/j.trgeo.2020.100358>.
- Indraratna, B.; Armaghani, D. J.; Gomes Correia, A.; Hunt, H. & Ngo, T. (2023). *Prediction of resilient modulus of ballast under cyclic loading using machine learning techniques*. Transportation Geotechnics, vol. 38. <https://doi.org/10.1016/j.trgeo.2022.100895>.
- Ling, X.; Li, P.; Zhang, F.; Zhao, Y.; Li, Y.; An, L. (2017). *Permanent deformation characteristics of coarse grained subgrade soils under train-induced repeated load*. Advances in Materials Science and Engineering, vol. 2017, pp 1-15. <https://doi.org/10.1155/2017/6241479>.
- Lopes, P.; Alves Costa, P.; Ferraz, M.; Calçada, R.; Silva Cardoso, A. (2014). *Numerical modeling of vibrations induced by railway traffic in tunnels: From the source to the nearby buildings*.

Soil Dynamics and Earthquake Engineering, Volumes 61–62, pp. 269–285.
<https://doi.org/10.1016/j.soildyn.2014.02.013>.

- Nielsen, J. C. O.; Li, X. (2018). *Railway track geometry degradation due to differential settlement of ballast/subgrade – Numerical prediction by an iterative procedure*. Journal of Sound and Vibration, vol. 412, pp. 441-456. <https://doi.org/10.1016/j.jsv.2017.10.005>.
- Olden, J. D.; Joy, M. K.; Death, R. G. (2004). *An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data*. Ecological Modelling, vol. 178, pp. 389-397. <https://doi.org/10.1016/j.ecolmodel.2004.03.013>.
- Pahno, S.; Yang, J.; Kim, S. (2021). *Use of Machine Learning Algorithms to Predict Subgrade Resilient Modulus*. Infrastructures, vol. 6, pp. 1-16. <https://doi.org/10.3390/infrastructures6060078>.
- Ramos, A.; Gomes Correia, A.; Calçada, R.; Alves Costa, P. (2021a). *Stress and permanent deformation amplification factors in subgrade induced by dynamic mechanisms in track structures*. International Journal of Rail Transportation, vol. 10, pp. 298-330. <https://doi.org/10.1080/23248378.2021.1922317>.
- Ramos, A.; Gomes Correia, A.; Calçada, R.; Alves Costa, P.; Esen, A.; Woodward, P. K.; Connolly, D. P.; Laghrouche, O. (2021b). *Influence of track foundation on the performance of ballast and concrete slab tracks under cyclic loading: Physical modelling and numerical model calibration*. Construction and Building Materials, vol. 277. <https://doi.org/10.1016/j.conbuildmat.2021.122245>.
- Ramos, A.; Gomes Correia, A.; Indraratna, B.; Ngo, T.; Calçada, R.; Costa, P. A. (2020). *Mechanistic-empirical permanent deformation models: Laboratory testing, modelling and ranking*. Transportation Geotechnics, vol. 23. <https://doi.org/10.1016/j.trgeo.2020.100326>.
- Ramos, A. L.; Correia, A. G.; Calçada, R.; Costa, P. A. (2018). *Influence of permanent deformations of substructure on ballasted and ballastless tracks performance*. Proceedings of 7th Transport Research Arena TRA 2018, April 16-19, 2018 Vienna, Austria. Zenodo.
- Rezaei-Tarahomi, A.; Kaya, O.; Ceylan, H.; Kim, S.; Gopalakrishnan, K.; Brill, D. R. (2017). *Development of rapid three-dimensional finite-element based rigid airfield pavement foundation response and moduli prediction models*. Transportation Geotechnics, vol. 13, pp. 81-91. <https://doi.org/10.1016/j.trgeo.2017.08.011>.
- Sadri, M.; Lu, T.; Zoeteman, A.; Steenbergen, M. (2018) *Railway track design & degradation*. In: Dimitrovová, Z., ed. MATEC Web of Conferences, Lisbon, Portugal.
- Sheng, X.; Jones, C. J. C.; Thompson, D. J. (2006). *Prediction of ground vibration from trains using the wavenumber finite and boundary element methods*. Journal of Sound and Vibration, vol. 293, pp. 575-586. <https://doi.org/10.1016/j.jsv.2005.08.040>.
- Sykora, D. W. (1987). *Creation of a data base of seismic shear wave velocities for correlation analysis*. Geotech. Lab. Miscellaneous Paper GL-87-26, U.S. Army Eng.
- Tinoco, J., Correia, A.; Cortez, P.; Toll, D. (2019). *Artificial Neural Networks for Rock and Soil Cutting Slopes Stability Condition Prediction: Proceedings of the 2nd GeoMEast International Congress and Exhibition on Sustainable Civil Infrastructures, Egypt 2018 – The Official International Congress of the Soil-Structure Interaction Group in Egypt (SSIGE)*. https://doi.org/10.1007/978-3-030-02032-3_10.

- Tinoco, J.; Gomes Correia, A.; Cortez, P. (2014). *Support vector machines applied to uniaxial compressive strength prediction of jet grouting columns*. Computers and Geotechnics, vol. 55, pp. 132-140. <https://doi.org/10.1016/j.compgeo.2013.08.010>.
- Tinoco, J.; Gomes Correia, A.; Cortez, P. (2018). *Jet grouting column diameter prediction based on a data-driven approach*. European Journal of Environmental and Civil Engineering, vol. 22, pp. 338-358. <https://doi.org/10.1080/19648189.2016.1194329>.
- Yang, Y.; Hung, H. (2001). *A 2.5D finite/infinite element approach for modelling visco-elastic body subjected to moving loads*. International Journal for Numerical Methods in Engineering vol 51, pp. 1317-1336. <https://doi.org/10.1002/nme.208>.