

# APLICAÇÃO DE MACHINE LEARNING EM SISTEMAS DE GESTÃO DE PAVIMENTOS

Pedro Marcelino<sup>1</sup>, Maria de Lurdes Antunes<sup>2</sup>, Eduardo Fortunato<sup>1</sup> e Marta Castilho Gomes<sup>3</sup>

<sup>1</sup>Laboratório Nacional de Engenharia Civil, Departamento de Transportes, Avenida do Brasil 101, 1700-066 Lisboa, Portugal

email: pmarcelino@lnec.pt <http://www.lnec.pt>

<sup>2</sup>Laboratório Nacional de Engenharia Civil, Conselho Diretivo, Avenida do Brasil, 1700-066 Lisboa, Portugal

<sup>3</sup>Instituto Superior Técnico, Departamento de Engenharia Civil, Arquitectura e Georrecursos, Avenida Rovisco Pais, 1049-001 Lisboa, Portugal

---

## Sumário

*O interesse do meio académico e empresarial pelas técnicas de machine learning tem sido crescente. Estas técnicas exploram algoritmos que aprendem com os dados e o seu sucesso tem sido notório em diversas áreas. Dado o potencial analítico destas técnicas, é esperado que as mesmas também possam ser aplicadas em sistemas de gestão de pavimentos. Neste artigo, apresentam-se alguns estudos nos quais se demonstra a aplicabilidade destas técnicas na gestão de pavimentos. Os resultados reportados são ilustrativos do potencial das técnicas de machine learning, sugerindo assim a viabilidade da sua aplicação em sistemas de gestão de pavimentos.*

---

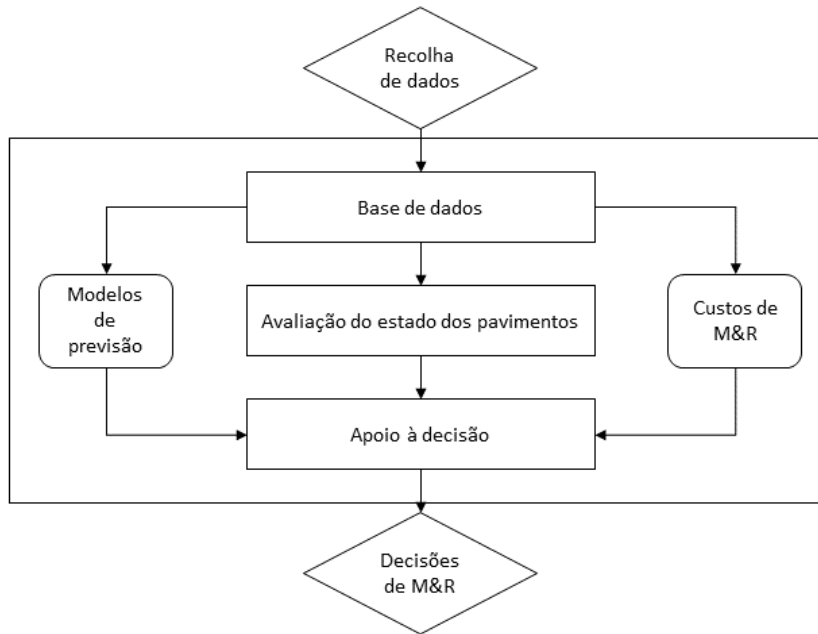
**Palavras-chave:** *Machine learning*; Sistemas de gestão de pavimentos; Gestão de ativos; Modelos de previsão de desempenho.

## 1 INTRODUÇÃO

Ao longo dos últimos anos, a utilização de *machine learning* tem-se tornado um tema capaz de despertar a curiosidade e o interesse do meio académico e empresarial. Alimentado por técnicas capazes de aprender com os dados, a aplicação de *machine learning* tem sido efetuada com sucesso nos mais diversos contextos. Este sucesso é sobretudo notório nas áreas que lidam com grandes volumes de informação e que ambicionam o desenvolvimento de modelos de previsão.

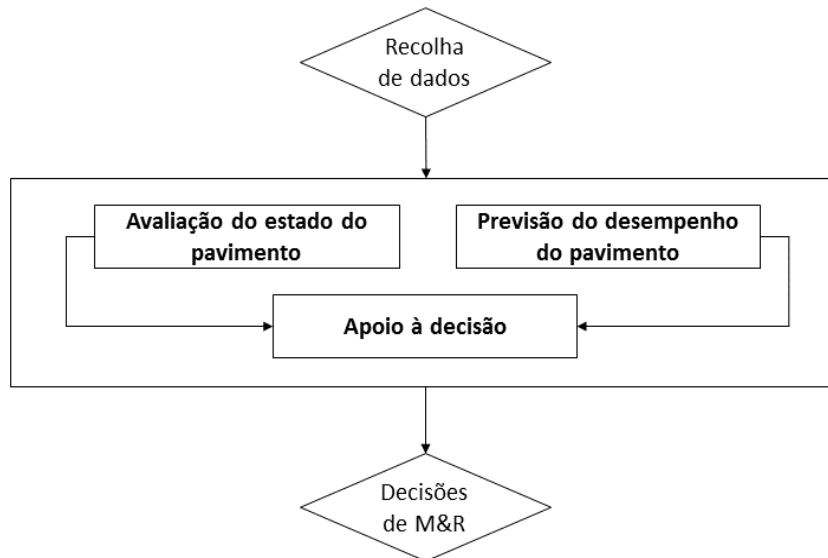
Na área dos Transportes, a aplicação de *machine learning* tem sido corrente na resolução de questões relacionadas com a mobilidade. Contudo, dado o seu potencial, é expectável que as técnicas de *machine learning* venham a ser cada vez mais frequentes em questões relacionadas com a gestão de infraestruturas. A capacidade que estas técnicas têm de analisar dados e estabelecer modelos de previsão assim o dita. Deste modo, a aplicação de *machine learning* em sistemas de gestão de pavimentos é não só esperada, como desejada [1].

De um modo geral, os sistemas de gestão de pavimentos podem ser representados de acordo com o disposto na Figura 1. Esta representação genérica considera o processo de gestão com a recolha dos dados que alimentam a base de dados da rede rodoviária. Tipicamente, estes dados permitem obter informações sobre a rede rodoviária, a estrutura dos pavimentos, o clima, o tráfego e o desempenho dos pavimentos. Com base nestes dados, é então possível: avaliar o estado do pavimento; estabelecer modelos de previsão de desempenho; e catalogar as intervenções de manutenção e reabilitação (M&R) [2]. Esta informação permite então que se tomem decisões relativas às intervenções a executar na rede rodoviária.



**Fig.1. Sistema de gestão de pavimentos (adaptado de [3])**

Assim sendo, é compreensível que a aplicação de *machine learning* em sistemas de gestão de pavimentos esteja segmentada de acordo com os diferentes componentes que constituem os mesmos. Na Figura 2 representa-se um esquema que enquadra aquilo que tem sido a investigação de *machine learning* em sistemas de gestão de pavimentos.



**Fig.2. Áreas de investigação de machine learning em sistemas de gestão de pavimentos.**

Por sua vez, apresenta-se no Quadro 1 alguma da investigação mais relevante que tem sido feita em cada uma das áreas de aplicação de *machine learning* em sistemas de gestão de pavimentos dispostas nas Figura 2. As referências do Quadro 1 foram obtidas através de uma pesquisa no Google Scholar, de acordo com as seguintes regras:

- (i) Combinações de dois tipos de palavras-chave. O primeiro referente às aplicações de *machine learning* em sistemas de gestão de pavimentos, nomeadamente ‘*pavement condition*’, ‘*pavement performance prediction*’, e ‘*pavement decision*’. O segundo referente a termos associados a *machine learning* (‘*machine learning*’, ‘*artificial intelligence*’, ‘*soft computing*’, ‘*data mining*’, ‘*knowledge discovery*’) e técnicas específicas (‘*artificial neural networks*’, ‘*classification and regression trees*’, ‘*support vector machines*’, ‘*k-nearest neighbors*’, ‘*naive bayes*’).
- (ii) Apenas foram considerados os artigos com um mínimo de 100 (se anteriores a 2000), 75 (se entre 2000 e 2009), e 25 (se entre 2010 e 2019) citações.
- (iii) Consultou-se um máximo de três páginas de resultados do *Google Scholar* por pesquisa.

Quadro 1. Investigação de *machine learning* em sistemas de gestão de pavimentos.

<b>Referência</b>	<b>Temática</b>	<b>Técnica de <i>machine learning</i></b>
Fwa et al.(1996) [4]	Apoio à decisão	Algoritmos genéticos
Hegazy & Ayed (1998) [5]	Apoio à decisão	Redes neuronais
Adeli & Wu (1998) [6]	Apoio à decisão	Redes neuronais
Attoh-Okine (1999) [7]	Previsão do desempenho do pavimento	Redes neuronais
Fwa et al. (2000) [8]	Apoio à decisão	Algoritmos genéticos
Cheng et al. (2001) [9]	Avaliação do estado do pavimento	Redes neuronais
Lee & Lee (2004) [10]	Avaliação do estado do pavimento	Redes neuronais
Wilmot & Mei (2005) [11]	Apoio à decisão	Redes neuronais
Chootinan et al. (2006) [12]	Apoio à decisão	Algoritmos genéticos
Terzi (2007) [13]	Avaliação do estado do pavimento	Redes neuronais
Omer & Fu (2010) [14]	Avaliação do estado do pavimento	Support vector machines
Lin & Liu (2010) [15]	Avaliação do estado do pavimento	Support vector machines
Bianchini & Bandini (2010) [16]	Previsão do desempenho do pavimento	Redes neuronais
Ngwangwa et al. (2010) [17]	Avaliação do estado do pavimento	Redes neuronais
Kargah-Ostadi et al. (2010) [18]	Previsão do desempenho do pavimento	Redes neuronais
Gavilán et al. (2011) [19]	Avaliação do estado do pavimento	Support vector machines
Yu & Salari (2011) [20]	Avaliação do estado do pavimento	Redes neuronais
Perttunen et al. (2011) [21]	Avaliação do estado do pavimento	Support vector machines
Shahnazari et al. (2012) [22]	Avaliação do estado do pavimento	Redes neuronais, algoritmos genéticos
Gopalakrishnan et al. (2017) [23]	Avaliação do estado do pavimento	Redes neuronais, random forests, support vector machines
Chen & Jahanshahi (2018) [24]	Avaliação do estado do pavimento	Redes neuronais, naïve bayes

Três tendências destacam-se no Quadro 1. A primeira refere-se à predominância da utilização de redes neurais. Dos 21 trabalhos citados, apenas sete não incluem a aplicação de redes neurais. Isto significa que mais de 65% da investigação relevante publicada recorre à utilização das redes neurais, verificando-se ainda que esta é a única técnica que figura nas três temáticas de aplicação de *machine learning* em sistemas de gestão de pavimentos. A predominância da aplicação de redes neurais na Engenharia Civil e na Engenharia de Pavimentos, em particular, encontra-se aliás denotada em estudos anteriores, tais como os realizados em [25] e [26].

Outra tendência observável no Quadro 1 é o surgimento de diversos trabalhos relacionados com a avaliação do estado dos pavimentos. Este crescimento é fortemente motivado pela aplicação de novas tecnologias na gestão de pavimentos, as quais incluem, por exemplo, o processamento avançado de imagens para a identificação de anomalias ([14], [15], [19], [23], [24], e a utilização de sensores para recolha de dados sobre o estado dos pavimentos ([17], [21]). Dado o avanço tecnológico a que se tem assistido ultimamente, é de esperar que estas áreas continuem a ter um volume crescente de investigação.

Por fim, verifica-se também que a partir de 2010 começam a ser aplicados outros tipos de técnicas. São exemplos disso a utilização de técnicas como *support vector machines*, *random forests* e *naive bayes*. A aplicação de técnicas diferentes está associada à aplicação de novas tecnologias na gestão de pavimentos, podendo também indiciar que a investigação na área de *machine learning* está a atingir um novo nível de desenvolvimento e interesse na Engenharia de Pavimentos.

Neste artigo pretende-se ilustrar algum do trabalho desenvolvido pelos autores no âmbito da aplicação de *machine learning* em sistemas de gestão de pavimentos. Estes trabalhos enquadram-se, sobretudo, na temática dos modelos de previsão de desempenho e visam responder com técnicas de *machine learning* a diferentes desafios que surgem na criação destes modelos, tal como se descreve em seguida.

## 2 MACHINE LEARNING EM SISTEMAS DE GESTÃO DE PAVIMENTOS

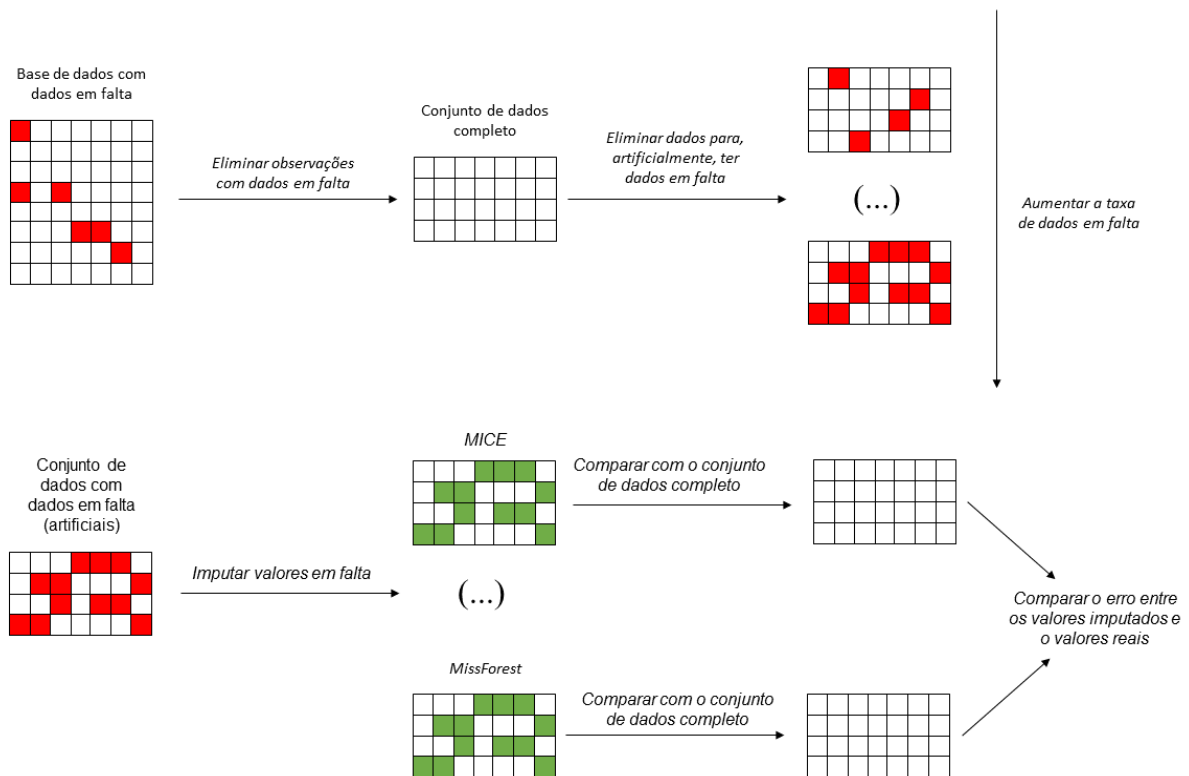
### 2.1 Imputação de dados em falta

A existência de dados em falta em determinadas observações é um problema comum nos sistemas de gestão de pavimentos [27]. Tal levanta problemas de ordem prática porque reduz o volume de dados disponíveis para o desenvolvimento de modelos de previsão do desempenho dos pavimentos. Consequentemente, a capacidade de previsão e de planeamento de intervenções dos sistemas de gestão de pavimentos fica limitada.

Na Engenharia de Pavimentos, este problema tem sido resolvido através da remoção das observações com dados em falta ou através do recurso à imputação de valores, nomeadamente, da média [28]. Apesar de correntes, estas técnicas possuem diversas limitações [29], motivando assim a procura de técnicas mais apropriadas.

Deste modo, foi realizado um estudo [30] comparativo no qual se aplicaram, em sistemas de gestão de pavimentos, três técnicas de *machine learning* populares na imputação de dados em falta. Estas técnicas foram: *MICE* [31], *KNN* [32], e *MissForest* [33]. Para efeitos de referência, também se incluiu no estudo a imputação de valores através da média.

A comparação das técnicas foi efetuada de acordo com o procedimento experimental ilustrado na Figura 3.



**Fig.3. Metodologia experimental.**

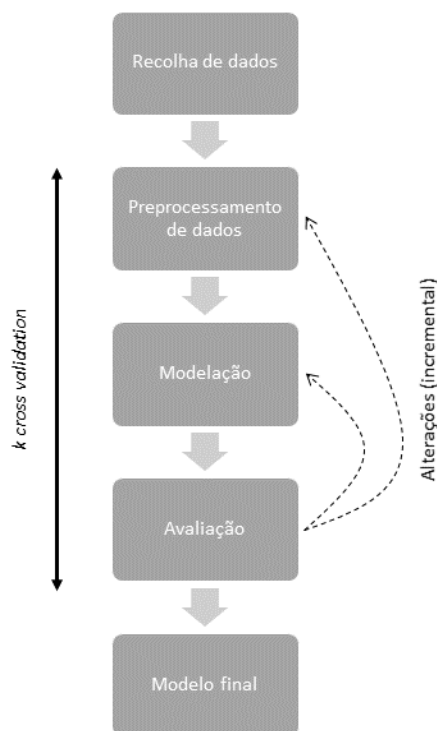
A técnica que obteve melhores resultados neste estudo foi a *MissForest*, apresentando o menor valor de erro (definido pela diferença entre os valores imputados e os valores reais). Em relação às restantes técnicas, esta técnica apresentou um erro inferior em 13,18% (KNN), 33,33% (MICE), e 45,74% (imputação da média). O estudo permitiu ainda concluir que, quando o volume de dados em falta é superior a 30%, nenhuma das técnicas é capaz de apresentar um desempenho fiável.

## 2.2 Previsão de desempenho dos pavimentos

Os modelos de previsão de desempenho são fundamentais para que os sistemas de gestão de pavimentos tenham um impacto positivo no processo de gestão da infraestrutura. Quanto mais correta for a previsão do estado dos pavimentos, melhor funcionarão os planos de manutenção e reabilitação. Do mesmo modo, uma correta previsão do estado dos pavimentos permite uma utilização mais eficaz e eficiente dos recursos disponíveis.

Como mencionado anteriormente, grande parte da investigação relacionada com a aplicação de *machine learning* para o desenvolvimento de modelos de previsão do desempenho dos pavimentos prende-se com a utilização de redes neuronais. A utilização desta técnica apresenta algumas limitações. Por exemplo, é sabido que as redes neuronais são propícias a fenómenos de *overfitting* [34], o que significa que os modelos funcionam bem com as observações utilizadas no seu desenvolvimento, mas não funcionam tão bem quando lidam com novas observações. Esta questão é especialmente premente quando os modelos têm como objetivo efetuar previsões, ou seja, estimar o comportamento do pavimento em situações novas.

No sentido de explorar a utilização de *machine learning* no desenvolvimento de modelos de previsão capazes de ultrapassar esta e outras limitações das redes neuronais, foram construídos modelos baseados num outro tipo de técnica: *random forests* [35]. Estes modelos foram construídos segundo um procedimento customizado, aplicável a qualquer outro algoritmo que se pretenda utilizar para o desenvolvimento de modelos de previsão de desempenho de pavimentos em redes rodoviárias [36]. A Figura 4 ilustra este procedimento.



**Fig.4. Desenvolvimento de modelos previsão de desempenho com base em *machine learning*.**

Para testar o procedimento descrito, realizou-se um caso de estudo utilizando a base de dados do *Long-Term Pavement Performance* (LTPP) [37]. Em particular, desenvolveram-se modelos de previsão para o *International Roughness Index* (IRI) [38] a 5 e 10 anos. Estes modelos tiveram em consideração aspetos como a estrutura do pavimento, o clima, e o tráfego, utilizando um máximo de 1370 observações. O erro dos modelos foi avaliado utilizando a técnica de *k-cross validation* [39] – técnica na qual são executadas várias simulações, nas quais uma parte das observações é utilizada para desenvolver o modelo e outra é utilizada para testar o mesmo, sendo o erro do modelo dado pela média do erro destas simulações – e comparando o seu desempenho com o desempenho de outros modelos publicados na literatura ([40], [41], [42]).

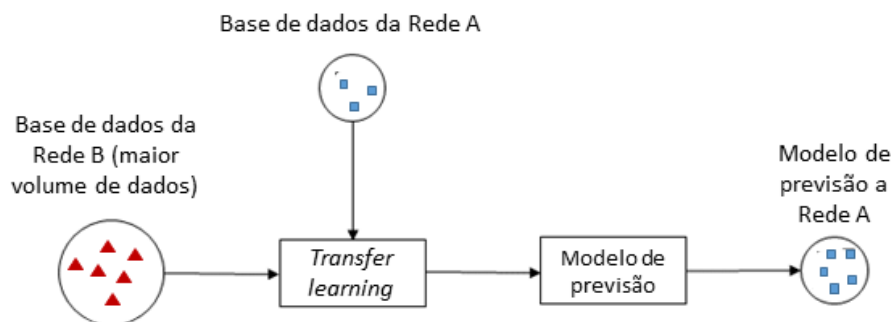
Concluiu-se que a utilização do procedimento proposto e de *random forests* permite desenvolver modelos de previsão adequados, quer para um horizonte temporal de 5 anos, quer para um horizonte temporal de 10 anos. Expresso em unidades de IRI, o erro médio do modelo de 5 anos foi de 0,253 m/km e o do modelo de 10 anos foi de 0,322 m/km. Dados os horizontes temporais, considerou-se que ambos os erros são aceitáveis. No referente à comparação dos modelos desenvolvidos com os modelos publicados na literatura, verificou-se que os modelos desenvolvidos são capazes de superar os modelos existentes.

### 2.3 Melhoria de modelos através de *transfer learning*

Durante as últimas décadas, diversas gestoras de infraestruturas rodoviárias têm enriquecido os seus sistemas de gestão de pavimentos e investido na recolha de dados necessários para o correto funcionamento dos mesmos. Apesar dos custos envolvidos nesta recolha, é conhecido que estes dados permitem a otimização dos processos de decisão e promovem a eficiente utilização de diversos tipos de recursos.

Contudo, verifica-se que as bases de dados ainda constituem um dos principais pontos críticos dos sistemas de gestão de pavimentos. Situações como a inexistência de um histórico de dados, a qualidade (ou falta da mesma) dos dados existentes, e a reduzida frequência com que os dados são recolhidos, condiciona a fiabilidade e a aplicabilidade prática das bases de dados dos sistemas de gestão de pavimentos.

No sentido de procurar enriquecer estas bases de dados, foi realizado um trabalho no qual se testou a aplicação de *transfer learning* no desenvolvimento de modelos de previsão do IRI [43]. A lógica geral do processo de *transfer learning* utilizado neste trabalho encontra-se descrita na Figura 5.



**Fig.5. Processo de *transfer learning*.**

Assim sendo, o estudo propôs a seguinte metodologia para o desenvolvimento de modelos de previsão nos casos em que a base de dados possui um reduzido volume de informação:

- (i) Identificar uma base de dados com uma estrutura semelhante e com um maior volume de dados.
- (ii) Identificar os dados passíveis de transferência.
- (iii) Estabelecer previsões com base nos dados transferidos e nos dados da base de dados original.

Esta metodologia foi aplicada num caso de estudo, o qual teve como objetivo o desenvolvimento de modelos de previsão do IRI para a rede rodoviária nacional. Dado o reduzido volume de informação da base de dados nacional, recorreu-se à base de dados do LTPP [37] para aumentar o volume de dados disponível para o desenvolvimento dos modelos de previsão. A identificação dos dados passíveis de transferência e a sua integração no modelo de previsão foi realizada através de uma versão modificada do *TrAdaBoost.R2* [44], um algoritmo correntemente aplicado em técnicas de *transfer learning*.

Os resultados obtidos permitiram concluir a validade da aplicação de técnicas de *transfer learning* para o desenvolvimento de modelos de previsão de desempenho. Graças ao enriquecimento da base de dados, foi possível obter uma redução do erro dos modelos na ordem de 20%.

### 3 CONCLUSÃO

Este artigo procurou mostrar o potencial da aplicação de *machine learning* em sistemas de gestão de pavimentos, através da descrição de alguns dos trabalhos desenvolvidos pelos autores neste domínio. Os trabalhos aqui resumidos prendem-se, essencialmente, com a aplicação de *machine learning* no desenvolvimento de modelos de previsão do desempenho dos pavimentos, uma das temáticas essenciais dos sistemas de gestão de pavimentos.

Depreende-se dos resultados obtidos nos diversos trabalhos realizados o potencial da aplicação de técnicas de *machine learning* em sistemas de gestão de pavimentos. Através da utilização de técnicas de *machine learning* foi possível: imputar dados em falta em bases de dados rodoviárias, melhorar os modelos de previsão de desempenho existentes, e transferir dados entre diferentes bases de dados de modo a possibilitar o desenvolvimento de modelos de previsão, mesmo em casos onde o volume de informação da base de dados é reduzido.

O potencial das técnicas de *machine learning* é imenso e tem vindo a ser demonstrado nas mais diversas áreas, sendo que a Engenharia de Pavimentos não é exceção. O amadurecimento da investigação na área de *machine learning* e a crescente utilização de novas tecnologias fazem com que, cada vez mais, seja necessário pensar na integração destas técnicas e tecnologias naquilo que é a atividade da Engenharia de Pavimentos. Esse é o desafio que cabe à comunidade técnica responder.

## 4 AGRADECIMENTOS

Este trabalho foi apoiado pela Fundação para a Ciência e a Tecnologia FCT através da bolsa SFRH/BD/129907/2017.

## 5 REFERÊNCIAS

1. P. Marcelino, L. Picado-Santos, M. L. Antunes, Aplicações de Inteligência Artificial na Avaliação de Pavimentos, *7º Congresso Rodoviário Português*, Lisboa, 28 a 30 de maio 2016.
2. P. Marcelino, M. L. Antunes, E. Fortunato, Comprehensive performance indicators for road pavement condition assessment, *Structure and Infrastructure Engineering*, 14(11), 2018.
3. L. Picado-Santos, A. Ferreira, A. Antunes, C. Carvalheira, B. Santos, M. Bicho, I. Quadrado, S. Silvestre, Pavement management system for Lisbon. *Proc. of the Institution of Civil Engineers-Municipal Engineer*, pp. 157-166, London, 2004.
4. T. F. Fwa, W. T. Chan, C. Y. Tan, Genetic-Algorithm Programming of Road Maintenance and Rehabilitation, *Journal of Transportation Engineering*, 122(3) 246–53, 1996.
5. T. Hegazy, A. Ayed, Neural Network Model for Parametric Cost Estimation of Highway Projects, *Journal of Construction Engineering and Management*, 124(3) 210–8, 1998.
6. H. Adeli, M. Wu, Regularization Neural Network for Construction Cost Estimation, *Journal of Construction Engineering and Management*, 124(1) 18–24, 1998.
7. N. O. Attoh-Okine, Analysis of learning rate and momentum term in backpropagation neural network algorithm trained to predict pavement performance, *Advances in Engineering Software*, 30(4) 291–302, 1999.
8. T. F. Fwa, W. T. Chan, K. Z. Hoque, Multiobjective Optimization for Pavement Maintenance Programming, *Journal of Transportation Engineering*, 126(5) 367–74, 2000.
9. H. D. Cheng, J. Wang, Y. G. Hu, C. Glazier, X. J. Shi, X. W. Chen, Novel Approach to Pavement Cracking Detection Based on Neural Network, *Transportation Research Record: Journal of the Transportation Research Board*, 1764(1) 119–27, 2001.
10. B. Lee, H. Lee, Position-Invariant Neural Network for Digital Pavement Crack Analysis, *Computer-Aided Civil and Infrastructure Engineering*, 19:105–18, 2004.
11. C. G. Wilmot, B. Mei, Neural Network Modeling of Highway Construction Costs, *Journal of Construction Engineering and Management*, 131(7) 765–71, 2005.
12. P. Chootinan, A. Chen, M. Horrocks, D. Bolling, A multi-year pavement maintenance program using a stochastic simulation-based genetic algorithm approach, *Transportation Research Part A*, 40 725–743, 2006.
13. S. Terzi, Modeling the pavement serviceability ratio of flexible highway pavements by artificial neural networks, *Construction and Building Materials*, 21(3) 590–3, 2007.
14. R. Omer, L. Fu, An automatic image recognition system for winter road surface condition classification, *Proc. 13th International IEEE Conference on Intelligent Transportation Systems*, Funchal, 2010.
15. J. Lin, Y. Liu, Potholes Detection Based on SVM in the Pavement Distress Image, *Proc. 9th International Symposium on Distributed Computing and Applications to Business, Engineering and Science*, pp. 544-547, 2010.
16. A. Bianchini, P. Bandini, Prediction of Pavement Performance through Neuro-Fuzzy Reasoning: Prediction of pavement performance through neuro-fuzzy reasoning, *Computer-Aided Civil and Infrastructure Engineering*, 25(1) 39–54, 2010.



17. H. M. Ngwangwa, P. S. Heyns, F. J. J. Labuschagne, G. K. Kululanga, Reconstruction of road defects and road roughness classification using vehicle responses with artificial neural networks simulation, *Journal of Terramechanics*, 47(2) 97–111, 2010.
18. N. Kargah-Ostadi, S. M. Stoffels, N. Tabatabaee, Network-Level Pavement Roughness Prediction Model for Rehabilitation Recommendations, *Transportation Research Record: Journal of the Transportation Research Board*, 2155(1) 124–33, 2010.
19. M. Gavilán, D. Balcones, O. Marcos, D. Llorca, M. Sotelo, I. Parra, M. Ocaña, P. Aliseda, P. Yarza, A. Amírola, Adaptive Road Crack Detection System by Pavement Classification, *Sensors*, 11(10) 9628-9657, 2011.
20. X. Yu, E. Salari, Pavement pothole detection and severity measurement using laser imaging, *Proc. IEEE International Conference On Electro/Information Technology*, pp. 1-5, 2011.
21. M. Perttunen, O. Mazhelis, F. Cong, M. Kauppila, T. Leppänen, J. Kantola, Distributed Road Surface Condition Monitoring Using Mobile Phones, *Proc. International Conference on Ubiquitous Intelligence and Computing*, pp. 64–78, Berlin, 2011.
22. H. Shahnazari M. A. Tutunchian, M. Mashayekhi, A. A: Amini, Application of Soft Computing for Prediction of Pavement Condition Index. *Journal of Transportation Engineering*. 138(12) 1495–506, 2012.
23. K. Gopalakrishnan, S. K. Khaitan, A. Choudhary, A. Agrawal, Deep Convolutional Neural Networks with transfer learning for computer vision-based data-driven pavement distress detection, *Construction and Building Materials*, 157 322–30, 2017.
24. F. C. Chen, M. R. Jahanshahi, NB-CNN: Deep Learning-Based Crack Detection Using Convolutional Neural Network and Naïve Bayes Data Fusion, *IEEE Transactions on Industrial Electronics*, 65(5) 4392–400, 2018.
25. H. Adeli, Neural networks in civil engineering: 1989–2000. *Computer-Aided Civil and Infrastructure Engineering*, 16(2) 126-42, 2001.
26. H. Ceylan, M. B. Bayrak, K. Gopalakrishnan, Neural networks applications in pavement engineering: A recent survey, *International Journal of Pavement Research and Technology*, 7(6) 434-44, 2014.
27. J. Farhan, T. F. Fwa, T.F., Improved imputation of missing pavement performance data using auxiliary variables, *Journal of Transportation Engineering*, 141(1), 2014.
28. M. M. Al-Zou'bi, C. M. Chang, S. Nazarian, V. Kreinovich, Systematic statistical approach to populate missing performance data in pavement management systems, *Journal of Infrastructure Systems*, 21(4) 04015002, 2015.
29. E. C. Tannenbaum, *The empirical nature and statistical treatment of missing data*. University of Pennsylvania, 2009.
30. P. Marcelino, M. L. Antunes, E. Fortunato, M. C. Gomes, Imputation of missing data in pavement management systems using machine learning methods, *18<sup>th</sup> Annual International Conference on Pavement Engineering, Asphalt Technology and Infrastructure*, Liverpool, 27-28 February 2019.
31. S. van Buuren, K. Groothuis-Oudshoorn, mice: Multivariate imputation by chained equations in R, *Journal of Statistical Software*, 45(3), 1-68, 2010.
32. O. Troyanskaya, M. Cantor, G. Sherlock, P. Brown, T. Hastie, R. Tibshirani, D. Botstein, D., R. B. Altman, Missing value estimation methods for DNA microarrays, *Bioinformatics*, 17(6) 520-525, 2001.
33. D. J. Stekhoven, P. Bühlmann, MissForest—non-parametric missing value imputation for mixed-type data, *Bioinformatics*, 28(1) 112-118, 2011.
34. N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, R. Salakhutdinov, R., Dropout: a simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15(1) 192-195, 2014.
35. L. Breiman, Random forests. *Machine learning*, 45(1) 5-32, 2001.

36. P. Marcelino, M. L. Antunes, E. Fortunato, M. C. Gomes, Machine learning approach for pavement performance prediction (revisão)
37. Long-Term Pavement Performance (LTPP), *LTPP DataPave Online* [base de dados]. Disponível em: <https://infopave.fhwa.dot.gov/> [Último acesso a 20 de março de 2018].
38. M. W. Sayers, S. M. Karamihas, *The Little Book of Profiling*, University of Michigan, 1998.
39. G. James, D. Witten, T. Hastie, R. Tibshirani, *An Introduction to Statistical Learning*, New York: Springer, 2013.
40. S. Gulen, K. Zhu, J. Weaver, J. Shan, W. Flora, *Development of improved pavement performance prediction models for the Indiana pavement management system*, Final Report, Indiana Department of Transportation, 2001.
41. S. Nassiri, M. H. Shafiee, A. Bayat, Development of roughness prediction models using alberta transportation, *International Journal of Pavement Research and Technology*, 6(6) 714-720, 2013.
42. F. Dalla Rosa, L. Liu, N. G. Gharaibeh, IRI Prediction Model for Use in Network-Level Pavement Management Systems. *Journal of Transportation Engineering Part B: Pavements*, 143(1), 2017.
43. P. Marcelino, M. L. Antunes, E. Fortunato, M. C. Gomes, Transfer Learning for pavement performance prediction (revisão)
44. D. Pardoe, P. Stone, Boosting for regression transfer, *Proc. 27th International Conference on Machine Learning*, pp. 863-870, 2010.