

Prediction of the sound absorption of porous concrete using machine learning approaches

Luís Filipe Monteiro Pereira^{1}*
Fernando José Forte Garrido Branco¹
Luís Manuel Cortesão Godinho¹
Paulo José da Venda Oliveira¹

¹Universidade de Coimbra, ISISE, ARISE, Departamento de Engenharia Civil, Coimbra

RESUMO

O comportamento acústico de materiais porosos à base de betão é uma temática sempre relevante em engenharia, na constante tentativa de controlo do ruído, em particular em ambientes externos. As estratégias de previsão baseiam-se geralmente em modelos teóricos, usando abordagens de fluido equivalente, e requerem o conhecimento a priori de uma série de parâmetros macroscópicos. No entanto, sua determinação nem sempre é simples ou sequer exequível, o que dificulta a aplicação geral desses modelos. Neste trabalho, uma abordagem baseada em aprendizagem computacional é implementada e testada para o caso específico de betão poroso com agregados de argila expandida. Assim, é utilizado um conjunto reduzido de parâmetros de entrada, o que constitui uma vantagem significativa quando comparado com modelos como Horoshenkhov-Swift ou Johnson-Champoux-Allard, permitindo uma previsão mais simples das características de absorção sonora destes materiais.

ABSTRACT

The acoustic behaviour of porous concrete-based materials is a relevant topic in noise control engineering, in particular in outdoor environments. Prediction strategies usually rely on theoretical models, using fluid-equivalent approaches, and require the a-priori knowledge of a number of macroscopic parameters. However, their determination is not always simple or even feasible, which hinders the general application of such models. In the present work, a *machine-learning* based approach is implemented and tested for the specific case of porous concrete with expanded clay aggregates. In this scope, a reduced set of input parameters is used, which constitutes a

significant advantage when compared with models such as Horoshenkhov-Swift or Johnson-Champoux-Allard, allowing for a simpler prediction of the sound absorption characteristics of such materials.

Palavras-chave – *redes neuronais artificiais, coeficiente de absorção sonora, acústica.*

1. INTRODUÇÃO

Os materiais porosos, em consequência de possuírem, entre outras características, baixa densidade, bom comportamento térmico e acústico (e aceitável, pelo menos para algumas finalidades, comportamento mecânico), são, atualmente, utilizados numa vasta gama de aplicações. São produzidos recorrendo a materiais como argila expandida, lava, xisto, ou cinzas vulcânicas, entre outros materiais [1]. A performance superior dos materiais porosos (relativamente ao betão de densidade normal, e nos aspetos mencionados acima) deve-se precisamente à estrutura porosa e à elevada resistência ao calor dos agregados que os compõem, o que pode traduzir-se numa redução significativa do consumo energético, em edifícios onde sejam aplicados [1]. Dada a sua eficácia no controlo passivo de ruído, são muitas vezes utilizados com essa finalidade, quer em espaços interiores quer em espaços exteriores.

No entanto, e dependendo da aplicação prática pretendida, é também extremamente importante definir (ou prever) outros parâmetros. Existem diversos modelos que permitem a previsão de propriedades acústicas a partir de parâmetros macroscópicos. Um exemplo destes modelos é o desenvolvido por Attenborough [2], que descreve características acústicas de materiais fibrosos e granulares a partir de cinco parâmetros:

¹ **Autor de contacto:** lfmpereira@student.uc.pt

porosidade, resistência ao fluxo, tortuosidade, o fator de forma e de fluxo constante e o fator de forma dinâmico.

Esta contextualização serve para salientar que o conhecimento não só dos parâmetros acústicos, mas também das propriedades intrínsecas dos materiais é de particular interesse [3], revela-se fundamental na estimativa dos seus comportamentos e serve diversos propósitos, tais como o controlo de qualidade durante o seu processo de fabrico ou a previsão do comportamento in-situ. Existem, claramente, esforços no sentido de se alcançar um único método de caracterização destes materiais, ou pelo menos um set reduzido de metodologias capazes de caracterizar a grande maioria de materiais acústicos [4].

Será assim extremamente útil o desenvolvimento de metodologias *machine learning* que possam ser aplicadas na previsão de parâmetros relevantes no comportamento acústico de materiais. Refira-se que existem já diversos estudos que recorrem a técnicas de *machine learning* para, por exemplo, prever o comportamento mecânico de betão composto por agregados leves, com recurso a programação de expressão genética [5] [6] [7], metodologias de inferência Bayesiana [8], ou mesmo redes neuronais artificiais [9].

2. REDES NEURONAIS ARTIFICIAIS

A aplicação de inteligência semelhante à humana em máquinas pode ser alcançada através da utilização de algoritmos de aprendizagem para, até certo ponto, mimetizar o modo de funcionamento (e de aprendizagem) do cérebro humano. O cérebro humano consegue, instantaneamente e sem dificuldade, processar uma sequência de algarismos manuscritos.

No entanto, escrever um código para compor um programa de computador que faça exatamente o mesmo que o nosso cérebro faz já não é tão simples. Uma tarefa tão elementar para o nosso cérebro como o reconhecer formas assume uma outra dimensão quando se pretende criar uma instrução automatizada.

As redes neuronais artificiais abordam esta questão de forma diferente. Tiram partido de uma base de dados de tamanho considerável que utilizam como exemplos de treino, e desenvolvem um sistema que aprende a partir destes exemplos de treino, ou, por outras palavras, inferem regras que lhes permitem reconhecer e classificar os dígitos manuscritos da figura 1 [10].

Como algoritmo supervisionado, uma rede neuronal artificial utiliza um dado set de parâmetros de entrada e de resposta e treina um modelo que possibilita a previsão desses parâmetros de resposta na presença de novos parâmetros de entrada, permitindo a comparação dos valores previstos com os valores reais, o que permite a melhoria da precisão do modelo de previsão.

Esta metodologia pode ser utilizada para facilitar atividades humanas de importância fundamental, como por exemplo em ensaios não destrutivos em contexto de monitorização da condição de estruturas já edificadas e em utilização, na

identificação e avaliação de patologias, avaliação do risco de deslizamentos de terra e acompanhamento do ritmo de desenvolvimento de fissuras através de emissões acústicas [11]–[14], previsão de parâmetros mecânicos e físicos [15]–[17] através da redução ou substituição completa de ensaios de laboratório ou de campo, avaliação do estado de meteorização de maciços rochosos [18] ou mesmo para prever parâmetros macroscópicos de materiais granulares, como porosidade [19], tortuosidade e permeabilidade através da análise de imagens [20], [21], propagação de ultrassons [22] ou coeficiente de absorção sonora [23].

3. METODOLOGIA

Para a realização deste estudo, foram utilizados resultados da absorção sonora reais de materiais porosos (betão poroso fabricado com argila expandida), obtidos em contexto de ensaios laboratoriais. Foram preparadas 3 misturas diferentes, com granulometrias variando entre 0-2mm, 2-4mm e 3-8mm.

Os resultados destes ensaios demonstraram a existência de correlações entre alguns destes parâmetros macroscópicos, nomeadamente entre a resistência ao fluxo de ar e a densidade, e entre a tortuosidade e o quociente entre a densidade e a porosidade [27]. De seguida, e considerando estas relações, simularam-se dados de coeficientes de absorção sonora no intervalo de frequências 125Hz-2000Hz, considerando parâmetros físicos específicos (tortuosidade, porosidade aberta, resistência ao fluxo, desvio padrão da dimensão dos poros, e a espessura) e parâmetros acústicos relevantes e que influenciam a absorção sonora dos materiais (número de onda e densidade complexos e compressibilidade), repetindo o procedimento 1500 vezes, de forma a criar uma base de dados de elementos sintéticos de dimensão considerável. Foi ainda adicionado um fator de erro aleatório, nunca superior a 5%, aquando da simulação dos parâmetros tortuosidade e resistência do fluxo de ar, assim como na determinação do coeficiente de absorção.

Posteriormente, desenvolveram-se modelos de aprendizagem computacional, recorrendo a redes neuronais artificiais (RNA).

Os dados gerados na primeira fase deste estudo foram utilizados no treino destes modelos *machine learning*, e os resultados são comparados com os resultados numéricos e experimentais. O modelo de RNA é composto por 3 camadas ocultas com 5 neurónios por camada, e aplica a função de ativação tansig (função de ativação hiperbólica sigmóide) na primeira e terceira camadas, e a função logsig (função de ativação logística sigmóide) na segunda camada (ver esquema geral na figura 1). Os resultados apresentam-se de seguida.




Figura 1- Esquema da rede neuronal desenvolvida

4. RESULTADOS

Foi determinada a correlação entre os parâmetros de entrada e o coeficiente de absorção, tendo-se observado que os fatores que mais influenciam o coeficiente de absorção são: a frequência e a espessura, seguidos dos parâmetros tortuosidade, porosidade aberta e resistência ao fluxo de ar, e finalmente o parâmetro desvio padrão da dimensão dos poros.

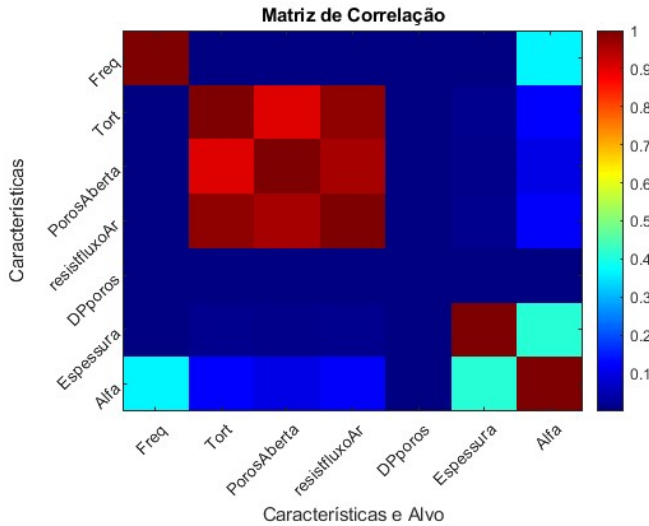


Figura 2 – Matriz de correlação entre os parâmetros de entrada e o alfa.

Face a esta correlação determinada, decidiu-se criar modelos de redes neuronais artificiais que considerassem um número variável de parâmetros de entrada (explanoado na Tabela 1).

Tabela 1 – Designação do modelo RNA desenvolvido, e parâmetros considerados.

DESIGNAÇÃO DO MODELO RNA	PARÂMETROS CONSIDERADOS
Modelo 2	Frequência e Porosidade aberta
Modelo 3	Frequência, Porosidade aberta, e Espessura
Modelo 4	Frequência, Porosidade aberta, Resist. Fluxo, e Espessura
Modelo 5	Frequência, Porosidade aberta, Resist. Fluxo, Tortuos., e Espessura
Modelo 6	Todos os parâmetros (6)

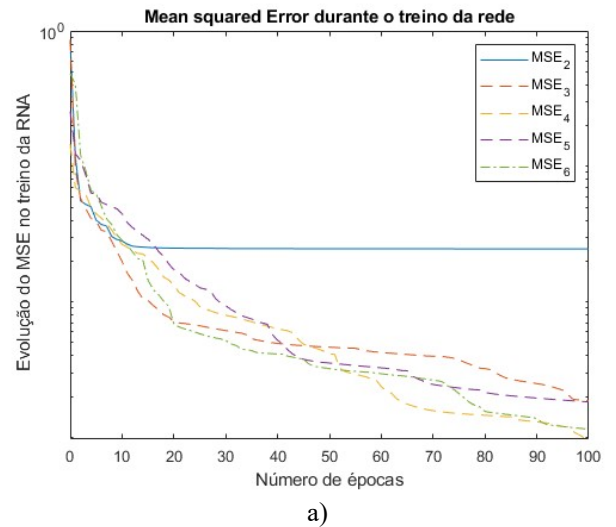
A figura seguinte (figura 3.a) apresenta a evolução de uma métrica de avaliação do treino de uma RNA, o Mean Squared Error (MSE) ao longo das 100 épocas de treino da RNA, determinado através da seguinte expressão (Eq 1).

$$MSE = \frac{1}{n} \sum_{i=1}^n (A_i - \hat{A}_i)^2 \quad (\text{Eq.1})$$

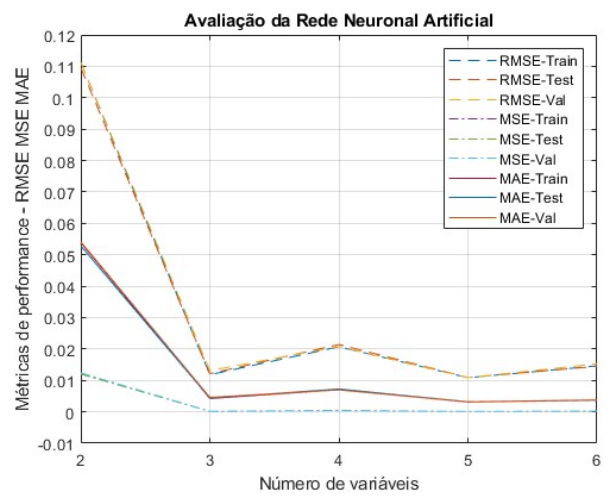
com n sendo o número total de dados, A_i os valores observados e \hat{A}_i os valores previstos pela RNA. A figura 3.b) apresenta o valor final para as métricas de avaliação RMSE, MSE e MAE obtidos pelo treino da RNA para os diferentes modelos treinados (desde 2 a 6 variáveis de entrada). Quanto mais baixos forem estes valores, mais preciso e fiável é o comportamento da rede. As métricas RMSE e MAE foram determinados pelas seguintes expressões (Eq. 2 e Eq. 3, respetivamente).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (A_i - \hat{A}_i)^2} \quad (\text{Eq.2})$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |A_i - \hat{A}_i| \quad (\text{Eq.3})$$



a)



b)

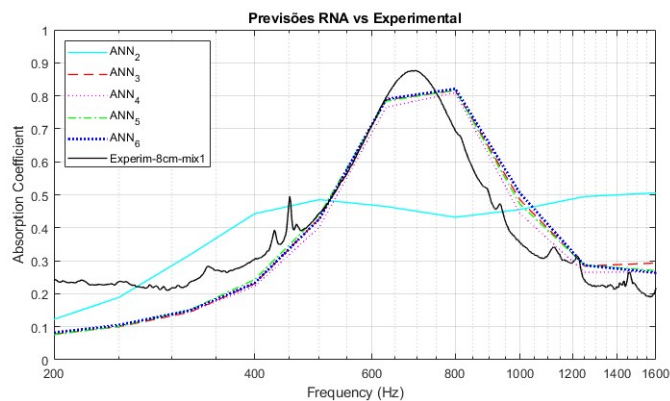
Figura 3 – Evolução do MSE ao longo do treino da RNA (a) Métricas de performance finais com diferentes número de variáveis (b).

Como se deprende da análise da figura 3.a), o modelo que considerou apenas duas variáveis não evoluiu de forma tão positiva como os restantes modelos, e isso traduz-se em previsões menos eficazes do coeficiente de absorção. O que se verifica também é que os modelos com melhor comportamento (nesta configuração, com estas configurações que influenciam os parâmetros macroscópicos), são os modelos treinados com 4 e 6 variáveis.


A figura 3.b) mostra que o modelo que considera apenas 2 variáveis não é satisfatório, apresentando os valores mais elevados de todas as métricas de avaliação. O que também se

pode concluir é que não existe grande melhoria destas métricas a partir do modelo que considera 3 variáveis (frequência, espessura e porosidade aberta), verificando-se uma tendência para uma horizontalização das curvas.


A figura 4 mostra a comparação entre as curvas do coeficiente de absorção previstas pelos diferentes modelos RNA desenvolvidos e a curva obtida através de ensaio laboratorial (curva a negro cheio), para 3 misturas diferentes. Salienta-se que o treino das RNA para cada mistura considerou as relações específicas entre os parâmetros de entrada, mencionados anteriormente.



a)



b)



c)

Figura 4 – Comparação entre as curvas previstas pelos modelos RNA e as curvas experimentais, para o parâmetro coeficiente de absorção, e para diferentes misturas (mistura 1 (fig. 4.a)) – mistura 2, (fig. 4.b)) – mistura 3 (fig. 4.c)).

Pode-se retirar da análise da figura anterior que os modelos de RNA desenvolvidos acompanham de modo muito evidente a curva obtida em laboratório, com a exceção óbvia do modelo que considerou apenas dois parâmetros, que se revelou claramente incapaz de prever o comportamento real das amostras ensaiadas.

Naturalmente, o modelo 6 revelou um comportamento bastante preciso e similar à curva experimental, no entanto, o modelo 3 já conseguiu previsões interessantes, conseguindo, a par do modelo 4, uma resposta praticamente idêntica (tendo até superado a previsão do modelo 6 no caso da mistura 3 com 4 centímetros de espessura.

5. CONCLUSÕES

A tentativa de previsão do comportamento acústico de materiais porosos à base de betão assume relevância considerável em engenharia baseia-se geralmente em modelos teóricos, usando abordagens de fluido equivalente, e exigem o conhecimento prévio de diversos parâmetros macroscópicos. Este trabalho demonstrou a adequabilidade da aplicação de metodologias *machine learning* na previsão do coeficiente de absorção sonora destes materiais, demonstrando que a utilização de um número reduzido de parâmetros macroscópicos no treino de modelos de RNA alcança resultados muito satisfatórios na previsão do coeficiente de absorção sonora de betões porosos. As métricas de avaliação MAE, MSE e RMSE demonstraram a convergência dos modelos desenvolvidos (com a exceção do modelo 2), e a comparação das curvas obtidas pelos modelos RNA e a curva obtida experimentalmente demonstrou a adequabilidade desta abordagem.

Adicionalmente, foi possível aferir que os modelos 3 e 4 alcançaram previsões muito próximas do modelo 6 (que considerava todos parâmetros), o que, aliado à tendência para a estagnação dos valores das métricas RMSE a partir do modelo 3 (observáveis na figura 3.b)), pode levar a concluir que serão modelos mais limpos e isentos de eventual ruído que a inclusão do parâmetro tortuosidade dos poros introduz no treino nos modelos 5 e 6.

FINANCIAMENTO:

Este trabalho foi parcialmente financiado pela FCT/MCTES através de fundos nacionais (PIDDAC) no âmbito da Unidade de I&D Instituto de Sustentabilidade e Inovação em Engenharia de Estruturas (ISISE), sob a referência UIDB/04029/2020, e no âmbito do Laboratório Associado Produção Avançada e Sistemas Inteligentes ARISE sob referência LA/P/0112/2020.

Este trabalho é financiado por fundos nacionais através da FCT – Fundação para a Ciência e a Tecnologia, ao abrigo do acordo de subvenção 2022.12096.BD atribuído ao 1º autor.

BIBLIOGRAFIA

- [1] A. Tanhadoust *et al.*, “Predicting stress-strain behavior of normal weight and lightweight aggregate concrete exposed to high temperature using LSTM recurrent neural network,” *Constr Build Mater*, vol. 362, p. 129703, 2023, doi: 10.1016/j.conbuildmat.2022.129703.
- [2] K. Attenborough, “Acoustical characteristics of rigid fibrous absorbents and granular materials,” *Journal of the Acoustical Society of America*, vol. 73, no. 3, pp. 785–799, 1983, doi: 10.1121/1.389045.
- [3] M. R. Stinson and Y. Champoux, “Propagation of sound and the assignment of shape factors in model porous materials having simple pore geometries,” *Journal of the Acoustical Society of America*, vol. 91, no. 2, pp. 685–695, 1992, doi: 10.1121/1.402530.
- [4] L. Jaouen, A. Renault, and M. Deverge, “Elastic and damping characterizations of acoustical porous materials: Available experimental methods and applications to a melamine foam,” *Applied Acoustics*, vol. 69, no. 12, pp. 1129–1140, 2008, doi: 10.1016/j.apacoust.2007.11.008.
- [5] S. Jafari and S. S. Mahini, “Lightweight concrete design using gene expression programming,” *Constr Build Mater*, vol. 139, pp. 93–100, 2017, doi: 10.1016/j.conbuildmat.2017.01.120.
- [6] V. N. Pham, E. Oh, and D. E. L. Ong, “Effects of binder types and other significant variables on the unconfined compressive strength of chemical-stabilized clayey soil using gene-expression programming,” *Neural Comput Appl*, vol. 34, no. 11, pp. 9103–9121, 2022, doi: 10.1007/s00521-022-06931-0.
- [7] H. Y. Leong, D. E. L. Ong, J. G. Sanjayan, and A. Nazari, “A genetic programming predictive model for parametric study of factors affecting strength of geopolymers,” *RSC Adv*, vol. 5, no. 104, pp. 85630–85639, 2015, doi: 10.1039/c5ra16286f.
- [8] S. C. Jong, D. E. L. Ong, and E. Oh, “A novel Bayesian inference method for predicting optimum strength gain in sustainable geomaterials for greener construction,” *Constr Build Mater*, vol. 344, no. June, 2022, doi: 10.1016/j.conbuildmat.2022.128255.
- [9] L. Pereira, L. Godinho, and F. G. Branco, “Predicting unconfined compression strength and split tensile strength of soil-cement via artificial neural networks,” *Geomechanics and Engineering*, vol. 33, no. 6, pp. 611–624, 2023, doi: 10.12989/gae.2023.33.6.611.
- [10] H. Wang, R. Czerminski, and A. C. Jamieson, *Neural Networks and Deep Learning*, vol. 25. Determination press San Francisco, CA, USA, 2021. doi: 10.1108/978-1-83909-694-520211010.
- [11] W. Mao, L. Hei, and Y. Yang, “Advances on the acoustic emission testing for monitoring of granular soils,”

- Measurement: Journal of the International Measurement Confederation*, vol. 185, p. 110110, 2021, doi: 10.1016/j.measurement.2021.110110.
- [12] H. Lo Lee, J. S. Kim, C. H. Hong, and D. K. Cho, "Ensemble learning approach for the prediction of quantitative rock damage using various acoustic emission parameters," *Applied Sciences (Switzerland)*, vol. 11, no. 9, p. 4008, 2021, doi: 10.3390/app11094008.
- [13] L. Deng, A. Smith, N. Dixon, and H. Yuan, "Machine learning prediction of landslide deformation behaviour using acoustic emission and rainfall measurements," *Engineering Geology*, vol. 293, pp. 1–16, 2021, doi: 10.1016/j.enggeo.2021.106315.
- [14] L. Deng, A. Smith, N. Dixon, and H. Yuan, "Machine learning prediction of landslide deformation behaviour using acoustic emission and rainfall measurements," *Engineering Geology*, vol. 293, no. 8, pp. 2959–2974, 2021, doi: 10.1016/j.enggeo.2021.106315.
- [15] X. Shi, Q. Liu, and L. Xiujuan, "Application of SVM in predicting the strength of cement stabilized soil," *Applied Mechanics and Materials*, vol. 160, pp. 313–317, 2012, doi: 10.4028/www.scientific.net/AMM.160.313.
- [16] S. Suman, M. Mahamaya, and S. K. Das, "Prediction of Maximum Dry Density and Unconfined Compressive Strength of Cement Stabilised Soil Using Artificial Intelligence Techniques," *International Journal of Geosynthetics and Ground Engineering*, vol. 2, no. 2, pp. 1–11, 2016, doi: 10.1007/s40891-016-0051-9.
- [17] P. Narloch, A. Hassanat, A. S. Tarawneh, H. Anysz, J. Kotowski, and K. Almohammadi, "Predicting compressive strength of cement-stabilized rammed earth based on SEM images using computer vision and deep learning," *Applied Sciences (Switzerland)*, vol. 9, no. 23, p. 5131, 2019, doi: 10.3390/app9235131.
- [18] M. E. Hatir, M. Barstuğan, and İ. İnce, "Deep learning-based weathering type recognition in historical stone monuments," *Journal of Cultural Heritage*, vol. 45, pp. 193–203, 2020, doi: 10.1016/j.culher.2020.04.008.
- [19] Y. Liu, M. Li, P. Su, B. Ma, and Z. You, "Porosity prediction of granular materials through discrete element method and back propagation Neural Network algorithm," *Applied Sciences (Switzerland)*, vol. 10, no. 5, p. 1693, 2020, doi: 10.3390/app10051693.
- [20] K. M. Graczyk and M. Matyka, "Predicting porosity, permeability, and tortuosity of porous media from images by deep learning," *Scientific Reports*, vol. 10, no. 1, pp. 1–11, 2020, doi: 10.1038/s41598-020-78415-x.
- [21] B. Boukhatem, R. Rebouh, A. Zidol, M. Chekired, and A. Tagnit-Hamou, "An intelligent hybrid system for predicting the tortuosity of the pore system of fly ash concrete," *Construction and Building Materials*, vol. 205, pp. 274–284, 2019, doi: 10.1016/j.conbuildmat.2019.02.005.
- [22] T. Lähivaara, L. Kärkkäinen, J. M. J. Huttunen, and J. S. Hesthaven, "Deep convolutional neural networks for estimating porous material parameters with ultrasound tomography," *The Journal of the Acoustical Society of America*, vol. 143, no. 2, pp. 1148–1158, 2018, doi: 10.1121/1.5024341.
- [23] J. H. Jeon, S. S. Yang, and Y. J. Kang, "Estimation of sound absorption coefficient of layered fibrous material using artificial neural networks," *Applied Acoustics*, vol. 169, p. 107476, 2020, doi: 10.1016/j.apacoust.2020.107476.
- [24] V. Kecman, *Support Vector Machines – An Introduction* BT - *Support Vector Machines: Theory and Applications*, vol. 47. Springer Science & Business Media, 2005.
- [25] N. Deng, Y. Tian, and C. Zhang, "Support vector machines: Optimization based theory, algorithms, and extensions," *Support Vector Machines: Optimization Based Theory, Algorithms, and Extensions*, pp. 1–315, 2012, doi: 10.1201/b14297.
- [26] S. Shalev-Shwartz and S. Ben-David, *Understanding machine learning: From theory to algorithms*, vol. 9781107057. Cambridge university press, 2013. doi: 10.1017/CBO9781107298019.
- [27] Pereira, M., Carbajo, J., Godinho, L., Amado-Mendes, P., Mateus, D., & Ramis, J. (2019). Acoustic behavior of porous concrete. Characterization by experimental and inversion methods. *Materiales de construcción*, 69(336), e202-e202.