

02-018 – Sustainable design of pervious concrete pavements to mitigate climate change in urban areas using neural networks – Diseño sostenible de pavimentos de hormigón poroso para mitigar el cambio climático en ciudades mediante redes neuronales

Wu, Yinglong¹; Pujadas Álvarez, Pablo¹; López Carreño, Rubén-Daniel¹; Pardo-Bosch, Francesc¹
(1) Universitat Politècnica de Catalunya

 Spanish  English

Climate change is increasing the frequency and intensity of extreme weather events, threatening the quality of life and health of people in urban environments. Among the main effects are flooding caused by torrential rains and rising temperatures due to the urban heat island effect. In this context, pervious concrete pavements can be a solution to address both challenges. Their high permeability minimizes surface runoff, while their evaporative cooling capacity reduces urban temperatures. Additionally, they offer added benefits such as groundwater recharge, improved road safety, and reduced energy consumption in adjacent buildings. However, the use of pervious concrete in pavements remains limited due to the lack of models to predict its mechanical strength and permeability. To address this issue, this study developed an optimized neural network-based model capable of accurately predicting both properties ($R^2 = 0.97$ and 0.98) based on the mix design materials. The results provide an efficient tool for designing pavements that foster more resilient and sustainable urban environments.

Keywords: *Pervious concrete; Climate change; Runoff; Urban heat islands; Neural networks*

El cambio climático está incrementando la frecuencia e intensidad de fenómenos meteorológicos extremos, amenazando la calidad de vida y la salud de las personas en los entornos urbanos. Entre los principales efectos destacan las inundaciones por lluvias torrenciales y el aumento de temperaturas debido al efecto isla de calor. En este escenario, los pavimentos de hormigón poroso pueden ser una solución que ayude a abordar ambos desafíos. Su alta permeabilidad minimiza las escorrentías superficiales, mientras que su capacidad de enfriamiento mediante evaporación disminuye las temperaturas urbanas. Además, ofrecen beneficios adicionales como la recarga de acuíferos, la mejora de la seguridad vial y la reducción del consumo energético de los edificios colindantes. No obstante, el uso del hormigón poroso todavía es limitado en pavimentos debido a la falta de modelos para predecir su resistencia mecánica y permeabilidad. Para dar respuesta a ello, en este trabajo se ha desarrollado un modelo optimizado basado en redes neuronales capaz de predecir ambas propiedades con elevada precisión ($R^2 = 0,97$ y $0,98$) a partir de los materiales de la dosificación. Los resultados proporcionan una herramienta eficiente para diseñar pavimentos que promuevan un entorno urbano más resiliente y sostenible.

Palabras claves: *Hormigón poroso; Cambio climático; Escorrentía; Islas de calor; Redes neuronales*



©2025 by the authors. Licensee AEIPRO, Spain. This article is licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).

1. Introducción

En los últimos años, los pavimentos de hormigón permeable (Pervious Concrete, PC) han ganado una atención creciente como una solución sostenible frente a los desafíos del desarrollo urbano acelerado (Adresi et al., 2023). Estos pavimentos permiten reducir eficazmente la acumulación de agua en superficie y mitigar los riesgos de inundaciones urbanas (Qin et al., 2018; Sappa et al., 2019), al mismo tiempo que favorecen la recarga de acuíferos gracias a su elevada permeabilidad (Kayhanian et al., 2019). Además, el color claro del hormigón contribuye a la reducción de la absorción de calor solar, atenuando así el efecto de isla de calor urbana (Adresi et al., 2024; Chen et al., 2019; Coseo & Larsen, 2015; Ibrahim et al., 2018; Lu et al., 2023).

Con el avance de las herramientas computacionales, el aprendizaje automático —y en particular las Redes Neuronales Artificiales (ANN, por sus siglas en inglés)— ha demostrado un gran potencial para abordar problemas complejos en la ingeniería civil, tales como la predicción de propiedades mecánicas y funcionales de materiales de construcción (Ikumi et al., 2021; Wu et al., 2024). A diferencia de los métodos tradicionales de diseño basados en prueba y error, los modelos ANN permiten procesar grandes volúmenes de datos experimentales y reconocer patrones no lineales, facilitando así la toma de decisiones más precisas y eficientes en el diseño de mezclas de hormigón permeable.

En este trabajo muestra el desarrollo de un modelo ANN para predecir la permeabilidad y la resistencia a compresión del hormigón poroso (PC). Para ello, se compiló una base de datos consistente en 271 dosificaciones de PC, con un total de 3.252 de datos experimentales. Con estos datos, se evaluaron 22.246 configuraciones de ANN mediante validación cruzada de Monte Carlo durante 20 iteraciones y con 4 algoritmos de entrenamiento diferentes, dando lugar a 1.779.680 ANN entrenadas. Como resultado, se obtuvo un modelo optimizado que incorpora múltiples parámetros de diseño de dosificaciones y predice con alta precisión la permeabilidad ($R^2 = 0,97$) y la resistencia a compresión ($R^2 = 0,98$). Finalmente, los análisis de sensibilidad confirmaron que el comportamiento del modelo está alineado con los principios teóricos establecidos del PC.

2. Revisión de la Literatura

El hormigón poroso se ha consolidado como una solución eficaz frente a los desafíos del desarrollo urbano, destacando por su capacidad para reducir el escurrimiento superficial y facilitar la recarga de acuíferos (Adab & Abbasi, 2024; Adams et al., 2004; Azad et al., 2024; de Sales Braga et al., 2022; Stephen et al., 2023). Sus propiedades clave —la permeabilidad y la resistencia a compresión— dependen de factores como la relación agua/cemento, el tamaño del agregado y la porosidad del sistema (Akkaya & Çağatay, 2021; Anwar et al., 2022; Boakye & Khorami, 2023).

En este contexto, las redes neuronales artificiales (ANN) han emergido como herramientas prometedoras para modelar comportamientos complejos del hormigón, mostrando buenos resultados en la predicción de resistencia y otras propiedades mecánicas (Ikumi et al., 2021; Wu et al., 2024).

Aunque diversos estudios han demostrado el potencial de las redes neuronales artificiales en la predicción de propiedades del hormigón poroso, en muchos casos los enfoques utilizados no exploran de forma sistemática una gran variedad de configuraciones de red ni aplican métodos estadísticos rigurosos de validación cruzada. En este sentido, persiste la necesidad de modelos que no solo sean precisos, sino también robustos y generalizables. Este estudio responde a esa necesidad mediante la implementación de un modelo optimizado que incorpora múltiples parámetros de entrada y valida su rendimiento mediante técnicas de

validación cruzada como Monte Carlo, con el fin de ofrecer una herramienta predictiva fiable para el diseño eficiente de pavimentos de hormigón poroso.

3. Recopilación de Datos

Para la selección del conjunto de datos, se realizó una búsqueda sistemática utilizando las bases de datos ScienceDirect y Scopus. La búsqueda se centró en artículos que contenían información detallada sobre el diseño de las dosificaciones, las propiedades hidráulicas (permeabilidad y porosidad) y las propiedades mecánicas (resistencia a compresión). Se excluyeron los artículos con información limitada, ya que era imperativo que los trabajos identificados proporcionasen información explícita para entrenar el modelo propuesto.

El conjunto de datos recogido estaba compuesto por 271 dosificaciones y 3.252 datos experimentales procedentes de diversos estudios (Nguyen et al., 2014; Barnhouse & Srubar, 2016; Elango & Revathi, 2017; Sandoval et al., 2017; Sandoval et al., 2019a; Sandoval et al., 2019a; Debnath & Sarkar, 2020; Martins et al., 2020; Pieralisi et al., 2020; Wang et al., 2020; Lo et al., 2021; Mehrabi et al., 2021; Muthukumar et al., 2021; Pieralisi et al., 2021; Wu et al., 2022; Lima et al., 2022).

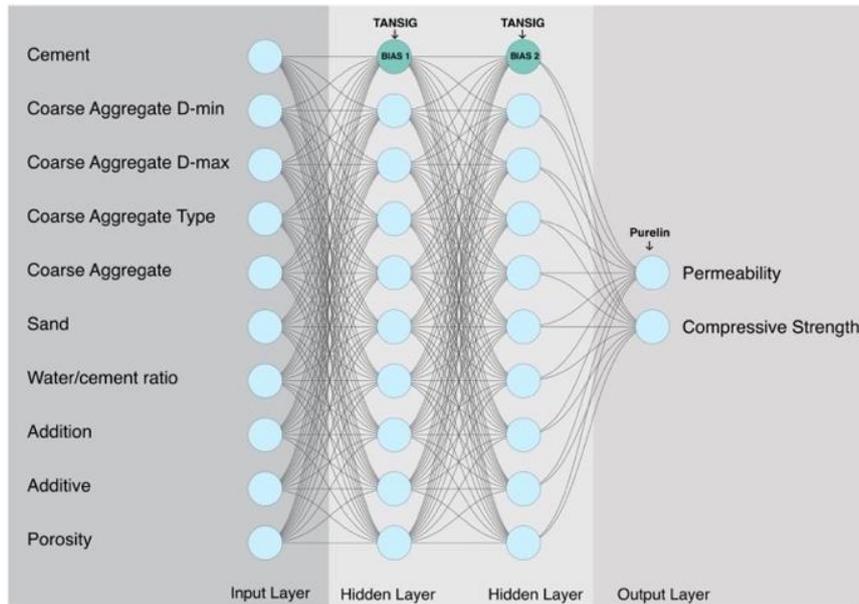
La base de datos recoge una gran variedad de dosificaciones de hormigón, abarcando diversos rangos de contenido de cemento (C_c), contenido de árido grueso (C_{Ag}), diámetro mínimo ($Ag. D_{min}$) y máximo ($Ag. D_{max}$) del árido grueso, tipo de árido grueso (Ag_{type}), contenido de arena (C_s), relación agua/cemento (a/c), contenido de adiciones (C_{Ad}), contenido de aditivos (C_{adt}), porosidad (P), permeabilidad (k) y resistencia a compresión (f_c).

4. Metodología y optimización de la ANN

Esta sección presenta la metodología utilizada para la obtención de la red neuronal artificial (ANN) optimizada para predecir la permeabilidad (k) y la resistencia a compresión (f_c) del hormigón poroso. Para ello, se utilizó una ANN del tipo perceptrón multicapa (MLP), implementada por completo en el software MATLAB (R-2023b). Desde el enfoque teórico de la estadística y el aprendizaje automático, la metodología también permite identificar la influencia relativa de cada parámetro de entrada en las variables de salida, lo que aporta una comprensión más profunda del comportamiento del material.

Se evaluaron arquitecturas MLP con una y dos capas ocultas, con el propósito de equilibrar la complejidad del modelo y la eficiencia computacional. La selección de estas profundidades se fundamenta en su capacidad demostrada para capturar relaciones no lineales complejas en los datos sin incurrir en sobreajuste. Como se muestra en la Figura 1, el número de variables de entrada en la capa de entrada varía progresivamente de 1 a 10 ($\mathbb{R}^{1:10}$), incluyendo cemento, relación a/c , entre otras. En la capa oculta, se consideraron arquitecturas de una o dos capas; la primera capa oculta varía de 1 a 10 neuronas ($\mathbb{R}^{1:10}$) y la segunda de 0 a 10 ($\mathbb{R}^{0:10}$), sin superar la cantidad de la primera. Cuando la segunda capa tiene 0 neuronas, el modelo se considera de una sola capa oculta. Las neuronas emplean la función de transferencia sigmoideal tangencial (Tansig), tal como se muestra en la Ecuación (1).

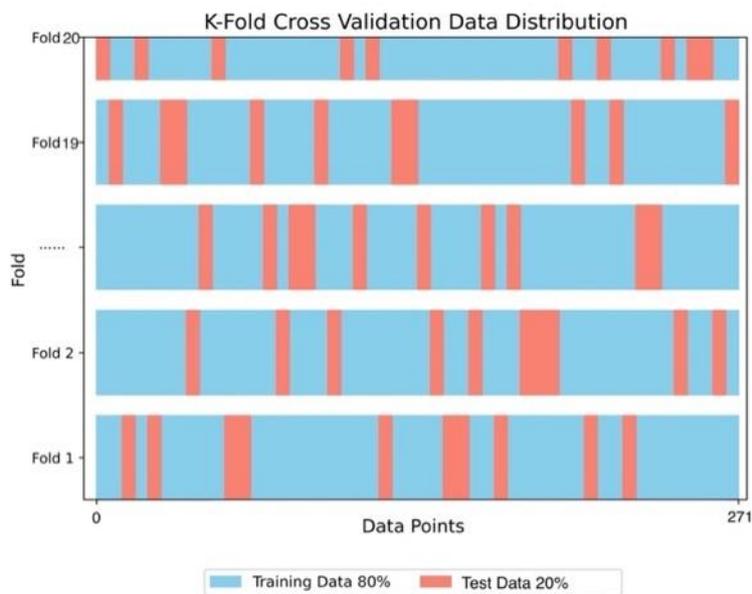
Figura 1: Arquitectura de la red neuronal artificial (ANN) con todas las características de entrada.



$$tansig = \frac{2}{1 + e^{-2i}} - 1 \quad (1)$$

La validación de cada configuración de red se llevó a cabo mediante validación cruzada de Monte Carlo (MCCV), con el fin de abordar la limitada cantidad de datos disponibles y reducir la varianza en la estimación del rendimiento del modelo. En total, se generaron 20 particiones *k-fold* ($k\text{-max} = 20$), utilizando el 80% de los datos para el entrenamiento y el 20% restante para la validación. La Figura 1 ilustra la distribución aleatoria de los datos de entrenamiento y prueba en cada iteración del proceso de validación cruzada de Monte Carlo.

Figure 2: Distribución de la validación cruzada K-fold.



El procedimiento *k-fold* divide aleatoriamente el conjunto de datos original en "*k*" particiones, denominadas "folds". En cada iteración, se emplea una partición para la validación y las restantes para el entrenamiento, lo que garantiza que los conjuntos de entrenamiento y prueba

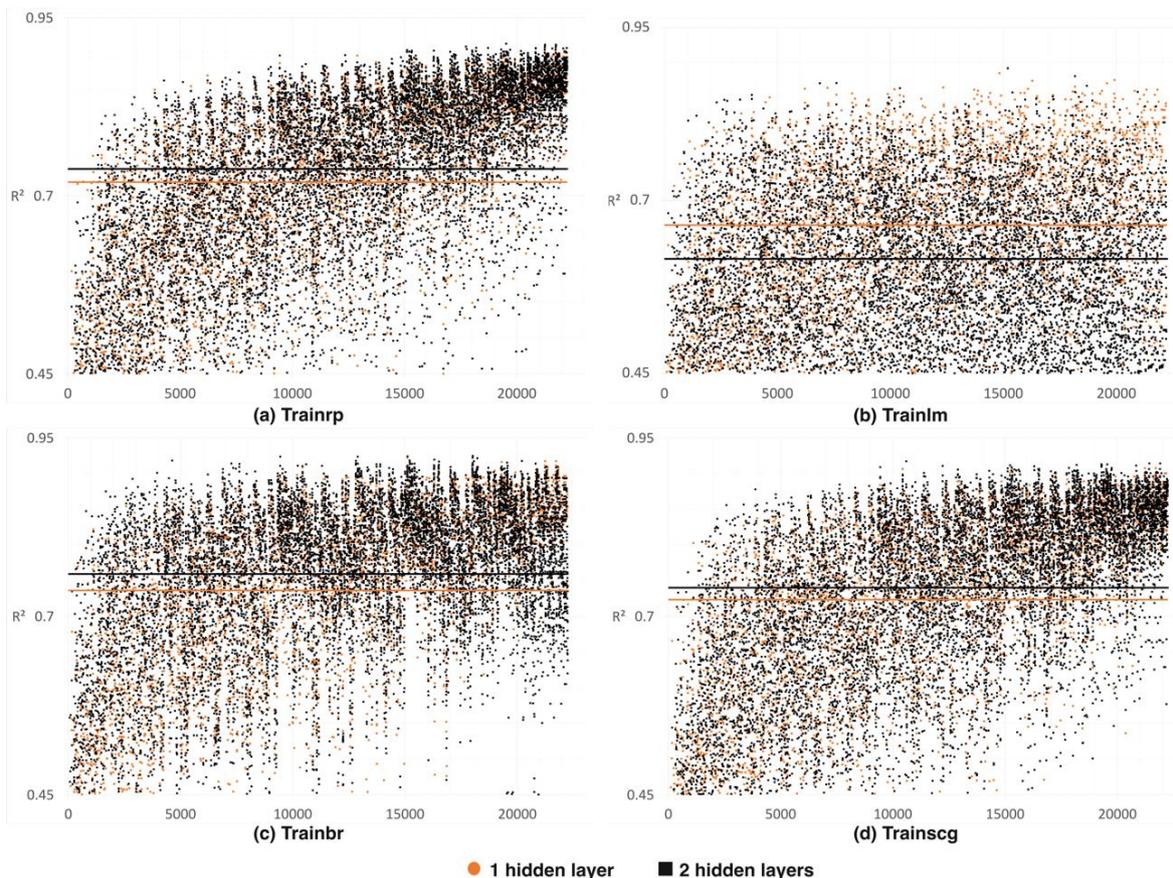
sean distintos en cada ciclo. Este enfoque reduce la aleatoriedad derivada de la selección de un único conjunto de prueba y contribuye a una evaluación más robusta y confiable del rendimiento del modelo. Finalmente, los resultados obtenidos en cada iteración se promedian para generar una estimación global del desempeño del modelo.

Además, se evaluaron cuatro algoritmos de entrenamiento para los modelos ANN en cada iteración del proceso de validación cruzada: propagación hacia atrás resiliente (*trainrp*), algoritmo de Levenberg-Marquardt (*trainlm*), regularización bayesiana (*trainbr*) y gradiente conjugado escalado (*trainscg*). Considerando un total de 22.246 configuraciones de red, 20 particiones (folds) y los cuatro algoritmos de entrenamiento, se llevaron a cabo 1.779.680 iteraciones de entrenamiento. El desempeño de cada modelo entrenado fue evaluado utilizando el coeficiente de determinación R^2 como métrica de ajuste.

5. Resultados

La Figura 3 presenta los valores de R^2 entre las estimaciones de los modelos y los valores reales utilizando los cuatro algoritmos de entrenamiento: “*trainrp*” (a), “*trainlm*” (b), “*trainbr*” (c) y “*trainscg*” (d). Los puntos naranjas corresponden a las configuraciones de ANN con una capa oculta, mientras que los de color negro están asociados a dos capas ocultas.

Figura 3: Valores promedio de R^2 correspondientes a diferentes cantidades de características de entrada: (a) *trainrp*, (b) *trainlm*, (c) *trainbr*, (d) *trainscg*.



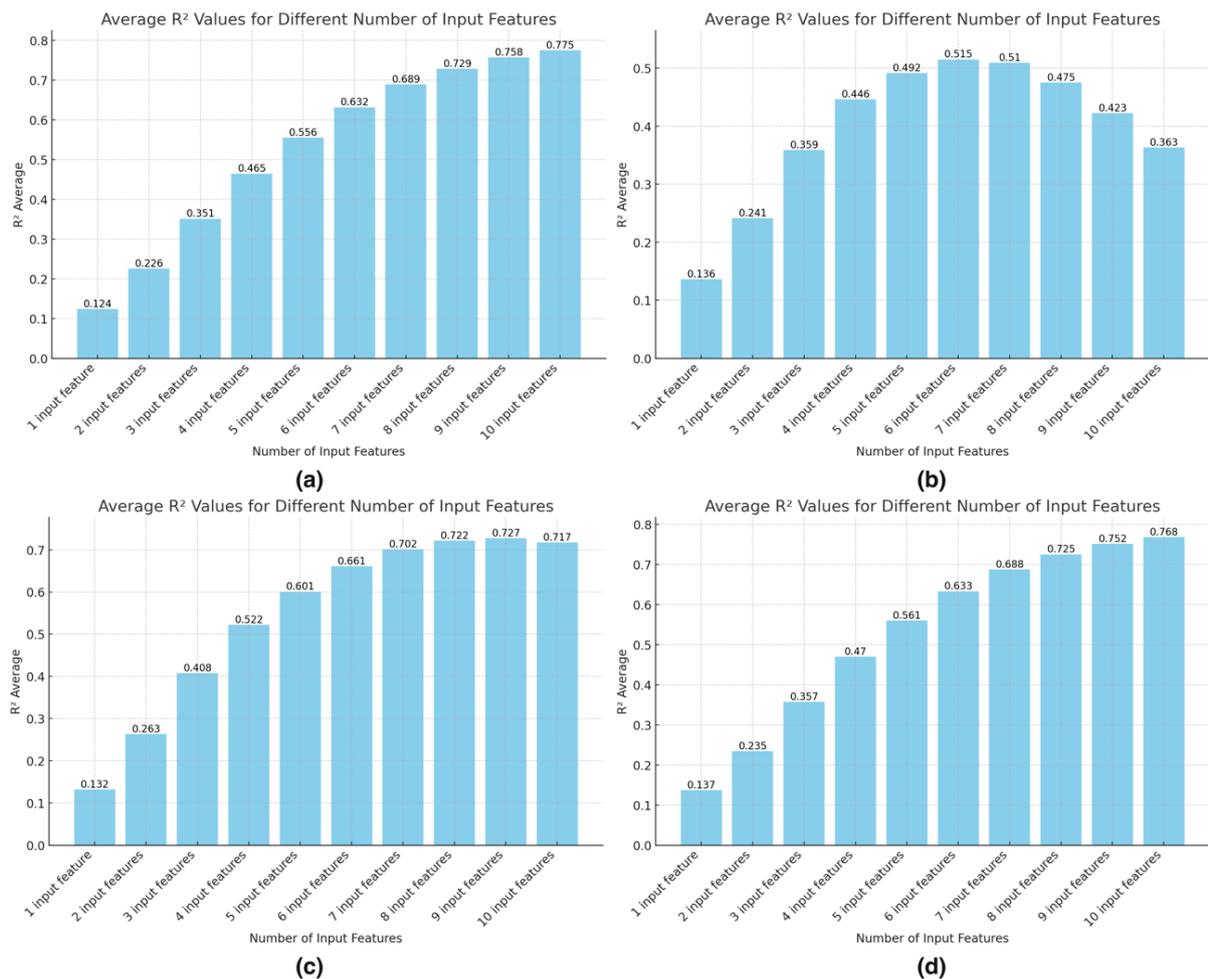
Al analizar los resultados se identifican áreas con diferentes densidades de distribución de los valores R^2 . Especialmente, cabe destacar aquellas áreas donde la densidad de puntos es mayor, que se produce, en general, cuando las configuraciones de los modelos se ajustan con mayor precisión a los datos.

Los resultados de los cuatro algoritmos de entrenamiento se muestran aquí únicamente para su comparación, ya que previamente se determinó que la mejor opción era entrenar con el algoritmo *trainrp*. Al comparar los valores promedio de R^2 en los dos casos con *trainrp*, el valor promedio de R^2 con dos capas ocultas (0.738) es ligeramente superior al de una capa oculta (0.719). Estos resultados indican que el aumento del número de capas ocultas tiene poco efecto en el rendimiento del modelo (Wu, 2024).

Para evaluar el rendimiento del modelo en función del número de variables de entrada, se presentan en la Figura 4 los valores promedio de R^2 para diferentes números de parámetros de entrada. En la subfigura (a), al utilizar el algoritmo de entrenamiento *trainrp*, se observa un incremento progresivo en el valor promedio de R^2 a medida que aumenta el número de variables, lo que sugiere una mejora en el ajuste del modelo a los datos conforme se incrementa el número de parámetros de entrada.

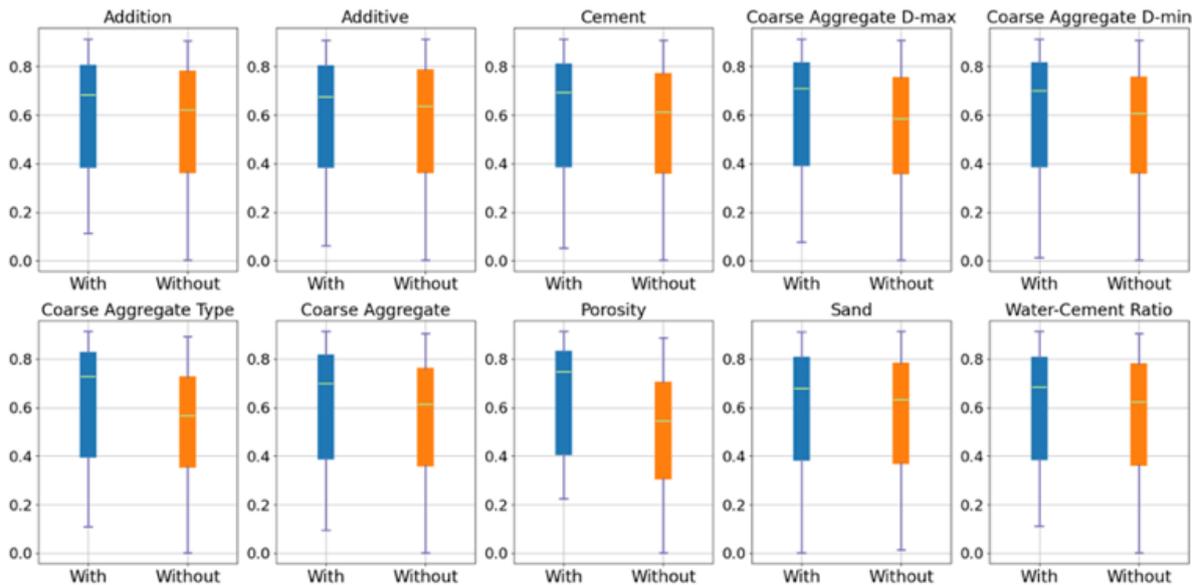
Los resultados indican que, en este caso, la adición de variables contribuye positivamente al desempeño del modelo, alcanzando un valor máximo de R^2 de 0.775 cuando se utilizan 10 variables. Por otro lado, los resultados obtenidos con los otros tres algoritmos de entrenamiento fueron ligeramente inferiores en comparación con *trainrp*. En particular, el algoritmo *trainlm* (subfigura (b)) presentó signos evidentes de sobreajuste y una tendencia decreciente en el rendimiento. En conclusión, cuando el modelo ANN incorpora 10 parámetros de entrada, es capaz de capturar de manera más efectiva los patrones y correlaciones subyacentes en los datos, lo que conduce a predicciones más precisas.

Figura 4: Comparación con diferente número de capas ocultas: (a) *trainrp*, (b) *trainlm*, (c) *trainbr*, (d) *trainscg*.



Por otro lado, la Figura 5 muestra la distribución de los valores de R^2 de los modelos entrenados en función de si estos incluyen (“with”, en azul) o no (“without”, en naranja) un determinado parámetro de entrada en su arquitectura. Con ello, es posible evaluar, en términos globales, el impacto individual de cada parámetro sobre la precisión de los modelos de ANN estudiados. La variable que tiende a generar una mayor variación de la precisión al tenerse en cuenta en los modelos es la porosidad, seguido por el tipo de agregado grueso.

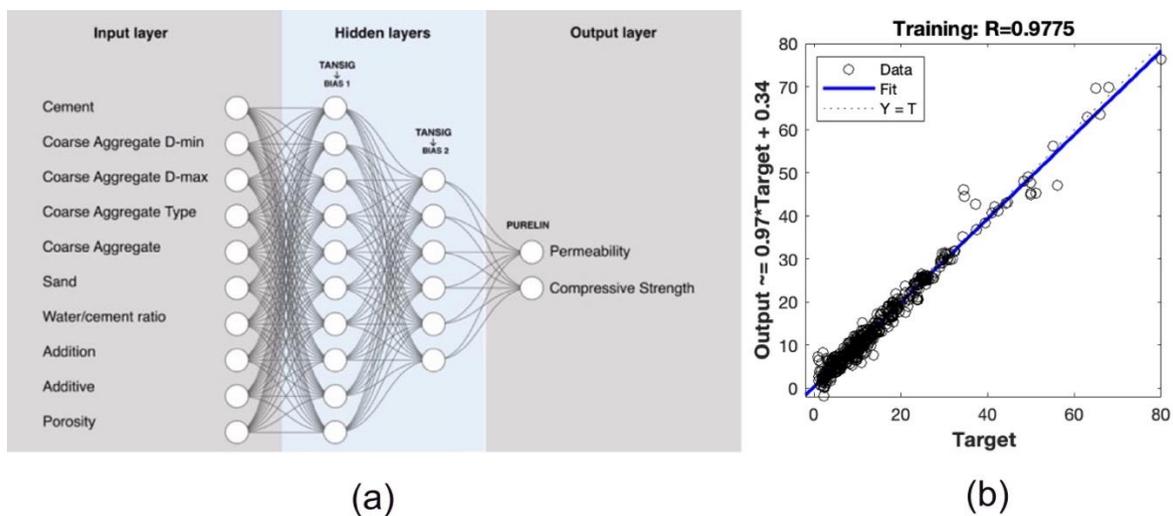
Figura 5: Efectos de los parámetros de entrada en los modelos ANN (*trainrp*).



6. Modelo Final

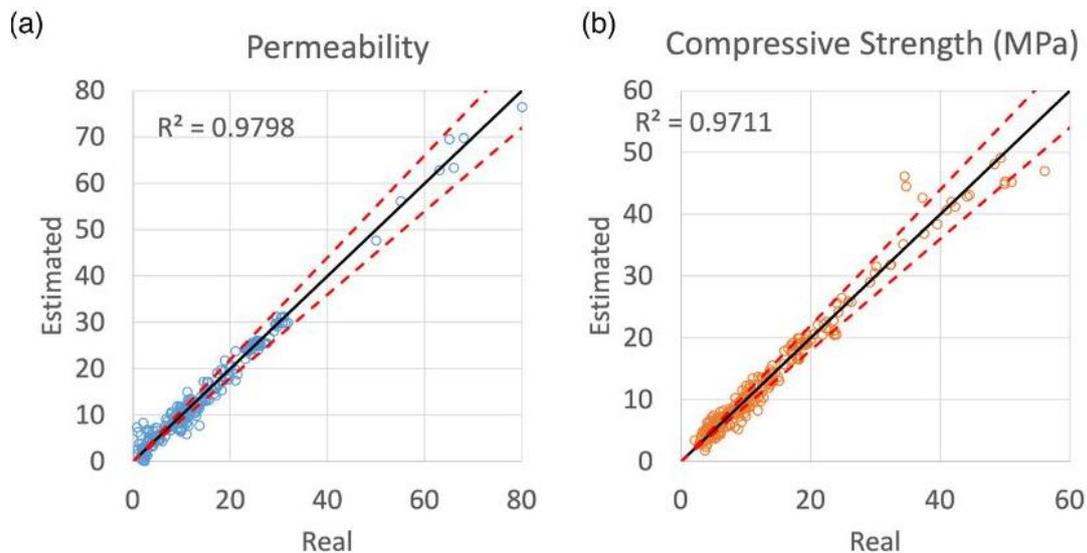
En la Figura 6 se presenta la estructura de la ANN multicapa optimizada, la cual consta de 10 parámetros de entrada relacionados con los materiales y la dosificación del hormigón poroso, 2 ocultas (la primera con 10 neuronas y la segunda con 6) y la permeabilidad y la resistencia compresión como parámetros de salida.

Figura 6: Predicción comparada con los valores reales ($R^2 = 0.9755$).



Por otro lado, las Figuras 7.a y b muestran, respectivamente, la precisión en la estimación de la permeabilidad y la resistencia a compresión la obtenida al entrenar la arquitectura de la ANN optimizada empleando la totalidad de la base de datos. En ambos casos, los valores de R^2 fueron muy próximos a 1,0, mostrando así una alta precisión de ajuste del modelo para ambas variables.

Figura 7: Precisión de la ANN optimizada.



7. Discusión

Los resultados obtenidos confirman el potencial de las redes neuronales multicapa para predecir con alta precisión las propiedades clave del hormigón poroso, superando las limitaciones de los métodos tradicionales de diseño basados en prueba y error. La alta precisión observada en la etapa de validación sugiere que el modelo puede ser una herramienta valiosa para ingenieros y diseñadores, permitiendo optimizar mezclas sin necesidad de realizar extensas campañas experimentales.

No obstante, puesto que el entrenamiento de los modelos se ha basado en datos de 16 estudios, su aplicación puede ser limitada, ya que en la práctica pueden darse casos de hormigones porosos con dosificaciones o materiales fuera del rango de los estudiados. En consecuencia, se recomienda que investigaciones futuras amplíen el rango de los datos de entrenamiento para extender la aplicabilidad de este tipo de modelos.

8. Conclusiones

En conclusión, este estudio muestra un caso de éxito de la aplicación de redes neuronales multicapa para predecir la permeabilidad y la resistencia a compresión del hormigón poroso. Gracias a ello, se da una respuesta a las limitaciones de los métodos de diseño actuales, los cuales se basan en prueba y error y requieren de la realización de campañas experimentales que tienen un consumo significativo de recursos y tiempo.

Este trabajo ha desarrollado un modelo optimizado de red neuronal multicapa que predice con alta precisión ambas propiedades clave del hormigón poroso, alcanzando coeficientes de determinación (R^2) superiores a 0,97. De este modo, se ofrece una herramienta eficiente y precisa como alternativa a los enfoques tradicionales de diseño, permitiendo reducir

considerablemente el tiempo y los recursos necesarios para caracterizar nuevas dosificaciones.

Además del desempeño predictivo alcanzado, este estudio pone de manifiesto el valor de enfoques basados en inteligencia artificial para modernizar procesos de diseño en la ingeniería civil. La estructura del modelo desarrollado permite adaptarlo fácilmente a nuevas bases de datos, lo que abre posibilidades para su actualización continua en función de avances experimentales o contextos regionales específicos. Asimismo, los resultados obtenidos refuerzan la viabilidad de aplicar metodologías similares en otros materiales porosos o soluciones de infraestructura sostenible, contribuyendo así al desarrollo de herramientas digitales orientadas a una construcción más eficiente y resiliente.

9. Referencias

- Adab, H., & Abbasi, M. (2024). Enhancing Runoff Treatment Using Green Porous Concrete Incorporating Recycled Aggregates. In *International Journal Of Environmental Science And Technology* (Vol. 21, Issue 16, Pp. 9853–9866). Springer. <https://doi.org/10.1007/S13762-024-05692-8>
- Adams, M. C., Cahill, T. H., Mullock, A. E., & Burgo, S. J. (2004). Porous Bituminous Pavement: A Stormwater Best Management Practice. In *Bridging The Gap: Meeting The World's Water And Environmental Resources Challenges—Proceedings Of The World Water And Environmental Resources Congress 2001* (Vol. 111). [https://doi.org/10.1061/40569\(2001\)195](https://doi.org/10.1061/40569(2001)195)
- Adresi, M., Yamani, A. R., & Tabarestani, M. K. (2024). Evaluating The Effectiveness Of Innovative Pervious Concrete Pavement System For Mitigating Urban Heat Island Effects, De-Icing, And De-Clogging. In *Construction And Building Materials* (Vol. 449). Elsevier Sci Ltd. <https://doi.org/10.1016/J.Conbuildmat.2024.138361>
- Adresi, M., Yamani, A., Tabarestani, M. K., & Rooholamini, H. (2023). A Comprehensive Review On Pervious Concrete. In *Construction And Building Materials* (Vol. 407). Elsevier Sci Ltd. <https://doi.org/10.1016/J.Conbuildmat.2023.133308>
- Akkaya, A., & Çağatay, İ. H. (2021). Investigation Of The Density, Porosity, And Permeability Properties Of Pervious Concrete With Different Methods. *Construction And Building Materials*, 294, 123539. <https://doi.org/10.1016/J.Conbuildmat.2021.123539>
- Anwar, F. H., El-Hassan, H., Hamouda, M., Hinge, G., & Mo, K. H. (2022). Meta-Analysis Of The Performance Of Pervious Concrete With Cement And Aggregate Replacements. In *Buildings* (Vol. 12, Issue 4). Mdpi. <https://doi.org/10.3390/Buildings12040461>
- Azad, A., Sheikh, M. N., & Hai, F. I. (2024). A Critical Review Of The Mechanisms, Factors, And Performance Of Pervious Concrete To Remove Contaminants From Stormwater Runoff. In *Water Research* (Vol. 251). Pergamon-Elsevier Science Ltd. <https://doi.org/10.1016/J.Watres.2024.121101>
- Barnhouse, P. W., & Srubar, W. V. (2016). Material Characterization And Hydraulic Conductivity Modeling Of Macroporous Recycled-Aggregate Pervious Concrete. *Construction And Building Materials*, 110, 89–97. <https://doi.org/10.1016/J.Conbuildmat.2016.02.014>
- Boakye, K., & Khorami, M. (2023). Influence Of Calcined Clay Pozzolan And Aggregate Size On The Mechanical And Durability Properties Of Pervious Concrete. In *Journal Of Composites Science* (Vol. 7, Issue 5). Mdpi. <https://doi.org/10.3390/Jcs7050182>

- Chen, J., Chu, R., Wang, H., Zhang, L., Chen, X., & Du, Y. (2019). Alleviating Urban Heat Island Effect Using High-Conductivity Permeable Concrete Pavement. In *Journal Of Cleaner Production* (Vol. 237). Elsevier Sci Ltd. <https://doi.org/10.1016/j.jclepro.2019.117722>
- Coseo, P., & Larsen, L. (2015). Cooling The Heat Island In Compact Urban Environments: The Effectiveness Of Chicago's Green Alley Program. In W. Chong, J. Chang, K. Parrish, & U. Berardi (Eds.), *Defining The Future Of Sustainability And Resilience In Design, Engineering And Construction* (Vol. 118, Pp. 691–710). Elsevier Science Bv. <https://doi.org/10.1016/j.proeng.2015.08.504>
- Debnath, B., & Sarkar, P. P. (2020). Characterization Of Pervious Concrete Using Over Burnt Brick As Coarse Aggregate. *Construction And Building Materials*, 242, 118154. <https://doi.org/10.1016/j.conbuildmat.2020.118154>
- De Sales Braga, N. T., Arruda Junior, E. S., & Pinheiro Cordeiro, L. De N. (2022). Performance And Runoff Coefficient Of Permeable Concretes Subjected To Heavy Rainfall Simulations. In *Materia-Rio De Janeiro* (Vol. 27, Issue 4). Univ Fed Rio De Janeiro, Lab Hidrogenio. <https://doi.org/10.1590/1517-7076-Rmat-2022-0216>
- Elango, K. S., & Revathi, V. (2017). Fal-G Binder Pervious Concrete. *Construction And Building Materials*, 140, 91–99. <https://doi.org/10.1016/j.conbuildmat.2017.02.086>
- Ibrahim, S. H., Ibrahim, N. I. A., Wahid, J., Goh, N. A., Koesmeri, D. R. A., & Nawi, M. N. M. (2018). The Impact Of Road Pavement On Urban Heat Island (Uhi) Phenomenon. *International Journal Of Technology*, 9(8), 1597–1608. <https://doi.org/10.14716/ijtech.V9i8.2755>
- Ikumi, T., Galeote, E., Pujadas, P., De La Fuente, A., & López-Carreño, R. D. (2021). Neural Network-Aided Prediction Of Post-Cracking Tensile Strength Of Fibre-Reinforced Concrete. *Computers & Structures*, 256, 106640. <https://doi.org/10.1016/j.compstruc.2021.106640>
- Kayhanian, M., Li, H., Harvey, J. T., & Liang, X. (2019). Application Of Permeable Pavements In Highways For Stormwater Runoff Management And Pollution Prevention: California Research Experiences. In *International Journal Of Transportation Science And Technology* (Vol. 8, Issue 4, Pp. 358–372). Elsevier B.V. <https://doi.org/10.1016/j.ijst.2019.01.001>
- Lima, G. T. Dos S., Rocha, J. C., & Cheriaf, M. (2022). Investigation Of The Properties Of Pervious Concrete With A Recycled Aggregate Designed With A New Combination Of Admixture. *Construction And Building Materials*, 340, 127710. <https://doi.org/10.1016/j.conbuildmat.2022.127710>
- Lo, F.-C., Lee, M.-G., & Lo, S.-L. (2021). Effect Of Coal Ash And Rice Husk Ash Partial Replacement In Ordinary Portland Cement On Pervious Concrete. *Construction And Building Materials*, 286, 122947. <https://doi.org/10.1016/j.conbuildmat.2021.122947>
- Lu, Y., Qin, Y., Huang, C., & Pang, X. (2023). Albedo Of Pervious Concrete And Its Implications For Mitigating Urban Heat Island. In *Sustainability (Switzerland)* (Vol. 15, Issue 10). Mdpi. <https://doi.org/10.3390/Su15108222>
- Martins Filho, S. T., Bosquesi, E. M., Fabro, J. R., & Pieralisi, R. (2020). Characterization Of Pervious Concrete Focusing On Non-Destructive Testing. *Revista Ibracon De Estruturas E Materiais*, 13(3), 483–500. <https://doi.org/10.1590/S1983-41952020000300003>
- Mehrabi, P., Shariati, M., Kabirifar, K., Jarrah, M., Rasekh, H., Trung, N. T., ... & Jahandari, S. (2021). Effect Of Pumice Powder And Nano-Clay On The Strength And Permeability Of Fiber-Reinforced Pervious Concrete Incorporating Recycled Concrete Aggregate.

- Construction And Building Materials, 287, 122652.
<https://doi.org/10.1016/j.conbuildmat.2021.122652>
- Muthukumar, S., Jai Saravanan, A., Raman, A., Shanmuga Sundaram, M., & Sri Angamuthu, S. (2021). Investigation On The Mechanical Properties Of Eco-Friendly Pervious Concrete. *Materials Today: Proceedings*, 46, 4909–4914.
<https://doi.org/10.1016/j.matpr.2020.10.333>
- Nguyen, D. H., Sebaibi, N., Boutouil, M., Leleyter, L., & Baraud, F. (2014). A Modified Method For The Design Of Pervious Concrete Mix. *Construction And Building Materials*, 73, 271–282. <https://doi.org/10.1016/j.conbuildmat.2014.09.088>
- Pieralisi, R., Cavalaro, S. H. P., & Aguado, A. (2021). Discrete Element Modelling Of Mechanical Behaviour Of Pervious Concrete. *Cement And Concrete Composites*, 119, 104005. <https://doi.org/10.1016/j.cemconcomp.2021.104005>
- Pieralisi, R., Sandoval, G. F. B., Segura-Castillo, L., Barbosa, M. N. C., & Assunção, S. T. (2020). Contribuição Para O Desenvolvimento De Uma Metodologia De Dosagem Para Concreto Permeável Baseada No Desempenho. *Journal Of Urban Technology And Sustainability*, 3(1), 18–27. <https://doi.org/10.47842/juts.v3i1.19>
- Qin, Y., He, Y., Hiller, J. E., & Mei, G. (2018). A New Water-Retaining Paver Block For Reducing Runoff And Cooling Pavement. *Journal Of Cleaner Production*, 199, 948–956. Scopus. <https://doi.org/10.1016/j.jclepro.2018.07.250>
- Sandoval, G. F. B., Galobardes, I., Teixeira, R. S., & Toralles, B. M. (2017). Comparison Between The Falling Head And The Constant Head Permeability Tests To Assess The Permeability Coefficient Of Sustainable Pervious Concretes. *Case Studies In Construction Materials*, 7, 317–328. <https://doi.org/10.1016/j.cscm.2017.09.001>
- Sandoval, G. F. B., Galobardes, I., Dias, C., Campos, A., & Toralles, B. M. (2019A). Pervious Concrete Made With Electric Furnace Slag (Fea): Mechanical And Hydraulic Properties. *Revista Ibracon De Estruturas E Materiais*, 12(3), 590–607. <https://doi.org/10.1590/S1983-41952019000300009>
- Sandoval, G. F. B., Galobardes Reyes, I., Schwantes-Cezario, N., Campos Moura, A., & Martins Toralles, B. (2019B). Correlation Between Permeability And Porosity For Pervious Concrete (Pc). *Dyna (Medellin)*, 86(209), 151–159.
- Sappa, G., Ferranti, F., Iacurto, S., & De Filippi, F. M. (2019). A Method To Contrast The Impact Of Extreme Precipitation: A Case Study From Central Italy. *3Rd World Multidisciplinary Civil Engineering, Architecture, Urban Planning Symposium (Wmcaus 2018)*, 471. <https://doi.org/10.1088/1757-899X/471/10/102052>
- Stephen, P., Mahmood, V., & Adishesu, S. (2023). Road Drains, An Efficient Tool For Groundwater Recharge-A Remote Sensing And Gis-Based Study On Visakhapatnam, Andhra Pradesh, India. In *Journal Of The Geological Society Of India (Vol. 99, Issue 11, Pp. 1539–1548)*. Geological Soc India. <https://doi.org/10.1007/S12594-023-2506-7>
- Wang, G., Chen, X., Dong, Q., Yuan, J., & Hong, Q. (2020). Mechanical Performance Study Of Pervious Concrete Using Steel Slag Aggregate Through Laboratory Tests And Numerical Simulation. *Journal Of Cleaner Production*, 262, 121208. <https://doi.org/10.1016/j.jclepro.2020.121208>
- Wu, F., Yu, Q., & Brouwers, H. J. H. (2022). Mechanical, Absorptive And Freeze–Thaw Properties Of Pervious Concrete Applying A Bimodal Aggregate Packing Model. *Construction And Building Materials*, 333, 127445. <https://doi.org/10.1016/j.conbuildmat.2022.127445>

Wu, Y., Perialisi, R., Sandoval, F. G. B., López-Carreño, R. D., & Pujadas, P. (2024). Optimizing Pervious Concrete With Machine Learning: Predicting Permeability And Compressive Strength Using Artificial Neural Networks. Construction And Building Materials. <https://doi.org/10.1016/j.conbuildmat.2024.137619>

Utilización de inteligencia artificial generativa

Durante la elaboración del presente trabajo, se ha recurrido al uso de ChatGPT únicamente para la revisión ortográfica y gramatical del texto. No se ha hecho uso de esta ni de ninguna otra herramienta de inteligencia artificial para actividades vinculadas al planteamiento, desarrollo, análisis o contenido de la investigación.

Comunicación alineada con los Objetivos de Desarrollo Sostenible

