

Can Artificial Intelligence Improve Nondestructive Evaluation of Concrete Strength?

by Seyed Alireza Alavi, Martin Noël, Hamed Layssi, and Farid Moradi

Compressive strength is commonly adopted as a representative indicator of many hardened properties of concrete. For existing structures, knowledge of in-place concrete properties is vital to any evaluation and rehabilitation project. Nevertheless, there exist several challenges associated with conventional methods for evaluating concrete strength once a structure has been built.¹⁻⁴ Core sampling is not always a viable option for many concrete structures (for example, concrete tanks, sewer trunks, and tunnel linings), and the representativeness of samples in large structures is difficult to obtain.

In-place nondestructive test (NDT) methods can be correlated to concrete compressive strength to reduce the number of required cores.⁵ The SonReb method⁶ estimates concrete compressive strength based on combined ultrasonic pulse velocity (UPV) and rebound number (RN) measurements. Like all NDT methods, project-specific calibration curves are required due to the heterogeneous nature and diversity of concrete mixtures⁷⁻⁹; hence, it is not currently possible to accurately estimate the concrete strength of existing structures without extraction of cores.

Artificial intelligence (AI) is a tool used to interpret complex information and increase productivity. The adoption of AI for civil engineering applications has been relatively slow but is beginning to garner increasing attention through demonstration of practical use cases. This article explores the extent to which AI can be integrated with the SonReb method for nondestructive evaluation of concrete compressive strength in reinforced concrete structures.

NDT Methods

ACI 228.2R-13⁵ provides a comprehensive overview of NDT methods for concrete strength evaluation, including the rebound hammer test (ASTM C805/C805M-08¹⁰) and UPV

measurements (ASTM C597-16¹¹). The rebound hammer test is an easy and cost-effective means of evaluating the in-place uniformity of concrete (primarily near the surface), while UPV measurements are generally used to evaluate the internal quality and integrity of concrete materials by measuring the velocity of compressive stress waves passing through a member.^{12,13} Theoretical formulations support the existence of a direct relationship between Young's modulus and wave velocity, while empirical relationships have long been established to link Young's modulus with compressive strength.¹⁴⁻¹⁶ Because of the challenges in predicting concrete strength by means of NDT resulting from inherent variabilities in concrete material properties, NDT methods, and physical/scientific connections and relevance between any NDT method and concrete strength, ACI Committee 228, Nondestructive Testing of Concrete, recommends the development of site/material specific calibration curves and a statistical approach to analyze the data. For existing structures, ACI 228.1R-19¹⁷ recommends that six to nine different locations should be selected for coring, and a minimum of two cores should be obtained to establish the in-plane compressive strength (that is, a minimum of 12 cores is needed to establish a strength relationship). EN13791:2019¹⁸ outlines a procedure that allows the use of RN measurements without any core tests under certain conditions, though this approach provides only conservative estimates of the strength class of concrete rather than accurate predictions of compressive strength.

NDT methods can be combined to improve their general reliability and reduce sensitivity to factors such as moisture content, aggregate size, cement type, and reinforcement ratio.^{14,19,20} The SonReb method has been proposed as a simple approach that nevertheless presents a notable improvement over single-input test methods. Some authors have suggested

that UPV and RN are distinctly affected by potential influencing factors,^{6,15,21} though, the extent to which this may be the case is still up for debate.

Artificial Intelligence

AI excels at predicting outcomes based on implicit relationships identified through various algorithms used to interpret large amounts of data. Machine learning (ML) is a subset of AI focusing on algorithms that enable computers to learn and make predictions or decisions without being

programmed.²²⁻²⁴ Figure 1 presents a flowchart for a typical supervised ML model. Two data sets are used in the modeling procedure: the training and the testing data set. Applying a learning algorithm to the training data, the computer “learns” potential relationships between input and output data. The testing data set is then used to evaluate the performance of the model, and the procedure is repeated until the ML model satisfies the evaluation criteria.

AI has recently been proposed as a tool to estimate the compressive strength of concrete based on the SonReb method.²⁵⁻³³ Although the results of previous studies are promising, there is still no practical model for use in the industry.²⁰ In a separate paper, the development of an ML model based on the SonReb method is described and compared to existing approaches.²² To emphasize simplicity and compatibility with current practice and considering the lack of concrete mixture information available for many existing structures, the ML model was developed with only two inputs: 1) pulse velocity from the direct UPV test; and 2) RN from the horizontal rebound hammer test as shown in Fig. 2. For the development of the ML model, a database was created using results from published literature as well as an experimental testing program with concrete cylinders and cubes between 7 to 365 days in age and representing a wide range of mixture designs and compressive strengths. (Additional details on the training and testing databases are presented elsewhere.²²)

The experimental procedure for each specimen tested in the laboratory included direct UPV tests, followed by the horizontal rebound hammer test, and finally, the compressive strength test on the same specimens, as shown in Fig. 3.

The model was developed using the adaptive neuro-fuzzy inference system (ANFIS) algorithm in MATLAB. To ensure a robust model performance and avoid a biased outcome, the training (462 data points) and testing data sets (20 data points) were obtained from distinct sources. The model performance was compared against linear and nonlinear regression analyses, as well as existing equations in the literature, and was found to provide the most reliable predictions of

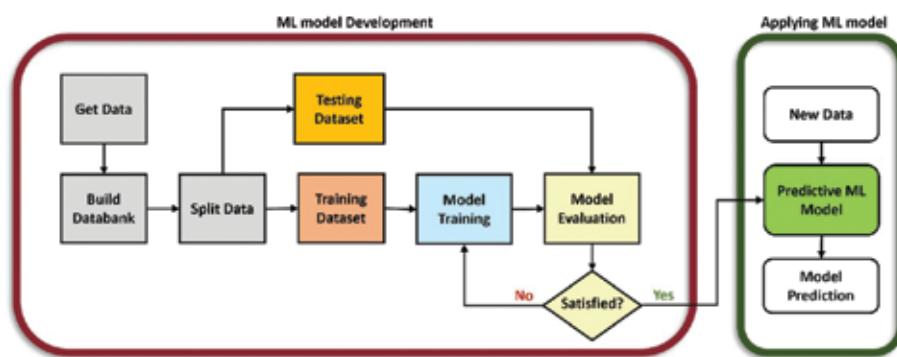


Fig. 1: Flowchart for supervised ML model

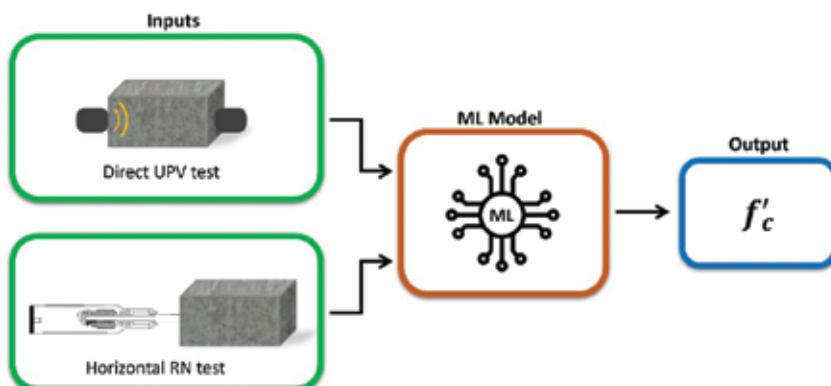


Fig. 2: ML model parameters

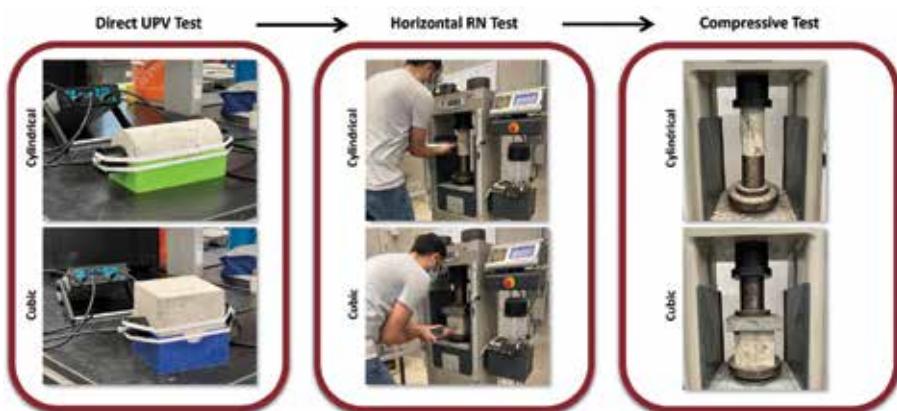


Fig. 3: Experimental test procedure

concrete strength among the considered models, with a mean absolute error of less than 10%.²² After developing the ML model, a graphical user interface (GUI) app was produced and used for three case studies that are presented in the following section. Each case study provided unique data that had not been seen by the model during its training phase. This approach was adopted to thoroughly evaluate the real-world performance of the ML model.

Case Studies

The accuracy of the model for real-world applications was evaluated using three case studies. In each case study, a systematic methodology was followed, including: 1) performing NDT (UPV and RN) on the concrete structures at select test areas; 2) extracting concrete core samples from the same test areas for compressive strength tests; 3) estimating compressive strength using the proposed ML model and traditional mathematical models, commonly known as the Breysse equation and the Gasparik equation; and 4) comparing the test results from each method.

Case Study 1: RC slab

A partially reinforced concrete slab was fabricated in the laboratory for an independent research project³² with overall dimensions of 2 x 2 m (6.5 x 6.5 ft) and 300 mm (12 in.) thick. The concrete for the slab was supplied from a local ready mixed concrete company. Twelve testing points (as shown in Fig. 4) were selected for this case study.

Figure 5 presents the test results. The best prediction was obtained from the proposed ML model with a mean absolute percent error (MAPE) of 9.69% and coefficient of variation (COV) of 6.1%. Breysse and Gasparik's equations produced average errors of 28.96% (COV 8.4%) and 36.35% (COV 6.2%), respectively, and both consistently overpredicted the compressive strength of the core samples.

Case Study 2: Existing concrete building

A two-story building on a university campus in Canada required in-place assessment of concrete members as part of its rehabilitation program. The predicted strength results are presented in Fig. 6. The MAPE of the ML model was 12.85% (COV 11.4%), while the errors of the Breysse and Gasparik equations were 19.79% (COV 18.9%) and 33.73% (COV 16.4%), respectively. The MAPE for the ML model reduces to 10.2% if the two column measurements (Col G4Z and Col G4) are excluded. The results suggest that the model performed generally better for flat slab and wall sections than for columns, although the reason for this discrepancy is still under investigation.

Case Study 3: Elevated foundation

A construction error in the elevated foundation of a storage silo in a mining facility resulted in poor consolidation of concrete and moderate to severe honeycombing on or around the lower layer of steel reinforcement, as well as the area

close to the embedded plates near the opening. A detailed test plan was designed to evaluate the damaged area (Fig. 7).

The results of the ML model and the Breysse and Gasparik equations are compared in Fig. 8. All of the predictive models tended to underpredict the concrete strength; Gasparik's equation had the lowest MAPE of 21.75% and COV of 17.02%, while both the ML model and Breysse's equation

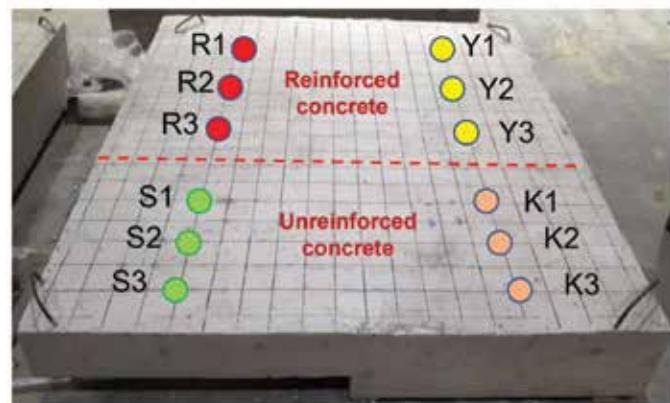


Fig. 4: RC slab with marked testing points (Note: 1 mm = 0.04 in.)

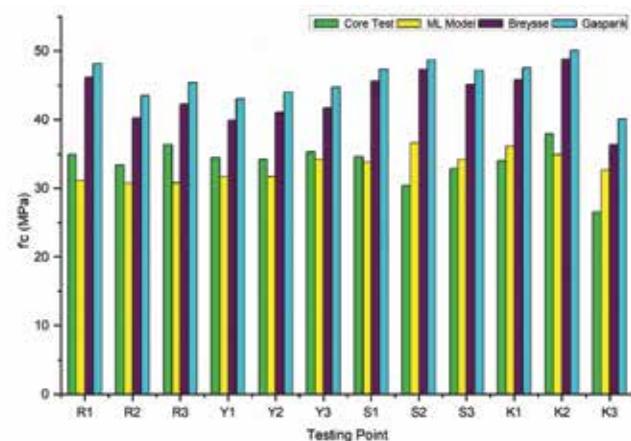


Fig. 5: Strength predictions for Case Study 1 (Note: 1 MPa = 145 psi)

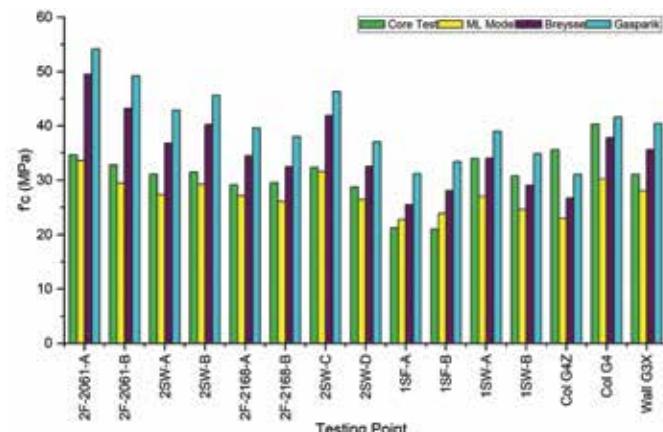


Fig. 6: Strength predictions for Case Study 2 (Note: 1 MPa = 145 psi)

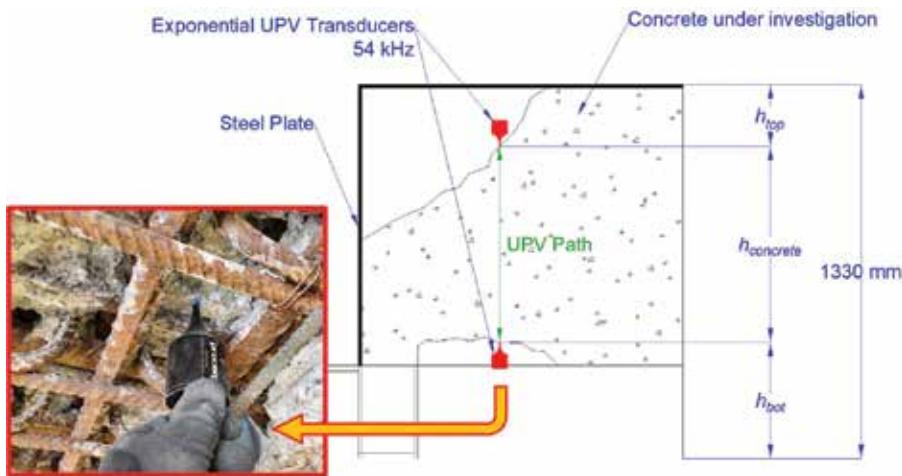


Fig. 7: UPV tests for Case Study 3 (Note: 1 mm = 0.04 in.)

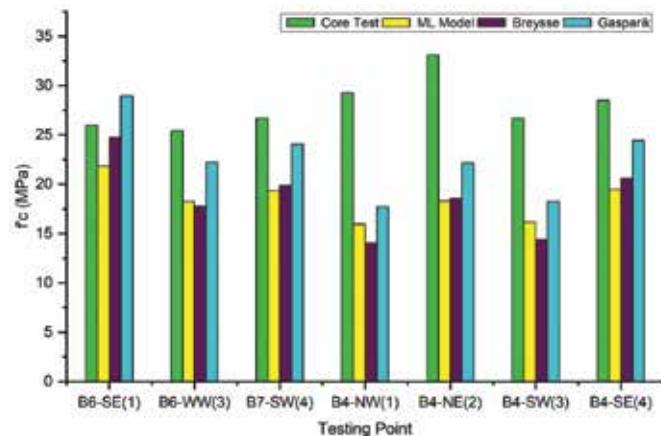


Fig. 8: Strength predictions for Case Study 3 (Note: 1 MPa = 145 psi)

gave similar performance (with average errors of 33.33% and 32.9%, and COV values of 11% and 20%, respectively).

Discussion

Concrete is a heterogeneous and diverse material. Compressive strength values obtained by crushing cylinders from a single batch of concrete can easily vary by 10% or more.^{33,34} In this context, achieving 100% accuracy from any model is unrealistic; ensuring consistency and reliability of predictions, as well as identifying potential model limitations, is a more important and achievable goal. This study has presented evidence that AI is a tool that can contribute toward this effort. And in the same way that all tools are used, engineering judgment is required to interpret the outcomes.

The AI model presented in this article maintains the simplicity of the SonReb method by keeping only two input parameters (UPV and RN).²² The benefits of this approach include more available data for model training, as well as wide applicability because no information on concrete mixture design, curing conditions, or age are required. As

demonstrated through the presented case studies, reasonably good predictions were obtained for sound reinforced concrete and flat surfaces with low to moderate amounts of reinforcement. Notable exceptions were obtained for columns in Case Study 2 (possibly attributed to higher reinforcement ratios or geometric effects) and for defective/damaged concrete in Case Study 3. In both cases, the model underpredicted the actual concrete strength by approximately 30% on average (that is, estimates were conservative). As further investigation on the effects of reinforcement congestion and member geometry on NDT measurements and associated model outputs are warranted,

it is unsurprising that the poor-quality concrete with visible honeycombing corresponded to a higher average error in the compressive strength predictions because all the training data was obtained from sound concrete specimens. This serves to highlight the engineer's role in interpreting results from tools such as AI. As AI models become more robust and larger training databases are available, their capabilities will also increase; while AI can increase our productivity, engineers will continue to play a vital role in the condition assessment of structures for the foreseeable future.

Ongoing work is currently being conducted to investigate whether model accuracy can be further improved by considering additional input parameters, such as geometry (which was initially ignored despite its known effect on concrete strength and NDT measurements), age, and basic mixture design parameters. The obvious challenge is that in order to consider more parameters, the size of the database must be correspondingly increased. Compiling sufficient good-quality data and filtering outliers/poor-quality results is a complex task; however, as seen in the proliferation of AI in other disciplines, the result can be quite powerful. Overall, the results obtained to date are encouraging and suggest that AI can be adapted to solve key challenges in the construction industry when sufficient data is available.

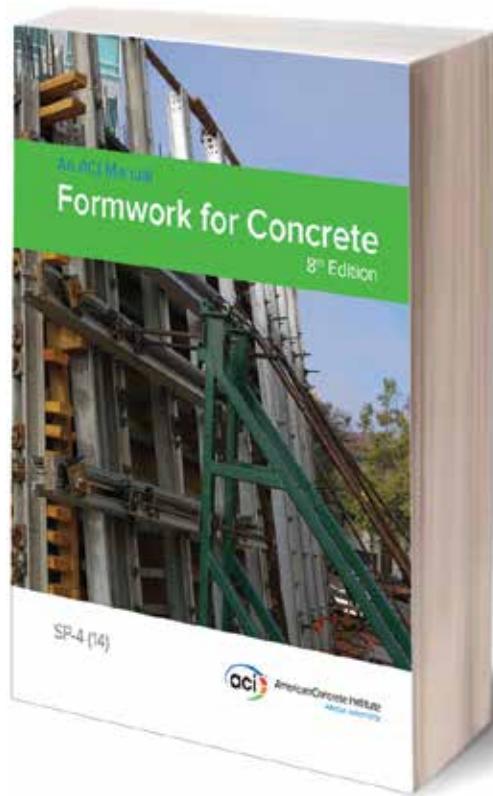
Finally, the importance of statistical/confidence level concepts to interpret ML predictions, as ACI 228.1R-19¹⁷ recommends for all cases, should not be overlooked. This is the subject of ongoing work by the authors and is an essential step for evaluating and applying model outcomes.

References

1. Breysse, D., and Balayssac, J.-P., *Non-Destructive In Situ Strength Assessment of Concrete*, Springer, 2021, 381 pp.
2. Pucinotti, R., "Reinforced Concrete Structure: Non-Destructive In-Situ Strength Assessment of Concrete," *Construction and Building Materials*, V. 75, Jan. 2015, pp. 331-341.
3. Breysse, D.; Soutsos, M.; Felicetti, R.; Krause, M.; Lataste,

- J.-F.; and Moczko, A., "How to Improve the Quality of Concrete Assessment by Combining Several NDT Measurements," *Proceedings of International Symposium on Non-Destructive Testing in Civil Engineering*, 2009, 8 pp.
4. Na, U.J.; Park, T.W.; Feng, M.Q.; and Chung, L., "Neuro-Fuzzy Application for Concrete Strength Prediction Using Combined Non-Destructive Tests," *Magazine of Concrete Research*, V. 61, No. 4, May 2009, pp. 245-256.
5. ACI Committee 228, "Report on Nondestructive Test Methods for Evaluation of Concrete in Structures (ACI 228.2R-13)," American Concrete Institute, Farmington Hills, MI, 2013, 82 pp.
6. RILEM, "Draft Recommendation for In Situ Concrete Strength Determination by Combined Non-Destructive Methods," *Materials and Structures*, V. 26, Jan. 1993, pp. 43-49.
7. Kouddane, B.; Sbartaï, Z.M.; Alwash, M.; Ali-Benyahia, K.A.; Elachachi, S.M.; Lamdouar, N.; and Kenai, S., "Assessment of Concrete Strength Using the Combination of NDT—Review and Performance Analysis," *Applied Sciences*, V. 12, No. 23, Nov. 2022.
8. Bolborea, B.; Dan, S.; Baeră, C.; Gruiu, A.; Enache, F.; and Perianu, I.A., "Study Regarding the Evaluation of Prediction Models for Determining the Concrete Compressive Strength Using Non-Destructive Testing (NDT) Data: Validation Stage," *Solid State Phenomena*, V. 332, May 2022, pp. 173-181.
9. Cristofaro, M.T.; Viti, S.; and Tanganelli, M., "New Predictive Models to Evaluate Concrete Compressive Strength Using the SonReb Method," *Journal of Building Engineering*, V. 27, Jan. 2020.
10. ASTM C805/C805M-08, "Standard Test Method for Rebound Number of Hardened Concrete," ASTM International, West Conshohocken, PA, 2008, 3 pp.
11. ASTM C597-16, "Standard Test Method for Pulse Velocity Through Concrete," ASTM International, West Conshohocken, PA, 2016, 4 pp.
12. Malek, J., and Kaouthier, M., "Destructive and Non-Destructive Testing of Concrete Structures," *Jordan Journal of Civil Engineering*, V. 8, No. 4, 2014, pp. 432-441.
13. Poorarbabi, A.; Ghasemi, M.R.; and Azhdari Moghaddam, M., "Conversion Factors Between Non-Destructive Tests of Cubic and Cylindrical Concrete Specimens," *AUT Journal of Civil Engineering*, V. 5, No. 1, 2021, pp. 3-16.
14. Breysse, D., "Nondestructive Evaluation of Concrete Strength: An Historical Review and a New Perspective by Combining NDT Methods," *Construction and Building Materials*, V. 33, Aug. 2012, pp. 139-163.
15. Rajabi, A.M.; Omidi Moaf, F.; and Abdelgader, H.S., "Evaluation of Mechanical Properties of Two-Stage Concrete and Conventional Concrete Using Nondestructive Tests," *Journal of Materials in Civil Engineering*, V. 32, No. 7, July 2020.
16. Agunwamba, J., and Adagba, T., "A Comparative Analysis of the Rebound Hammer and Ultrasonic Pulse Velocity in Testing Concrete," *Nigerian Journal of Technology*, V. 31, No. 1, Mar. 2012, pp. 31-39.

Formwork for Concrete 8th Edition



Updated to current standards.



Allowable strength design, load, and resistance factor design examples.



Chapter problems for classroom study.

available at
concrete.org

Member Price: \$149.00
Regular Price: \$249.50



American Concrete Institute
Always advancing



17. ACI Committee 228, "Report on Methods for Estimating In-Place Concrete Strength (ACI 228.1R-19)," American Concrete Institute, Farmington Hills, MI, 2019, 48 pp.
18. "EN 13791:2019: Assessment of In-Situ Compressive Strength in Structures and Precast Concrete Components," CEN-CENELEC Management Centre, Brussels, Belgium, 2019, 41 pp.
19. Kayed, A.R., "The Strength of Concrete in Existing RC Structures," MS thesis, Politecnico di Torino, Turin, Italy, July 2021, 67 pp.
20. Alavi, S.A., and Noël, M., "Challenges for the Development of Artificial Intelligence Models to Predict the Compressive Strength of Concrete Using Non-Destructive Tests: A Review," *Proceedings of the Canadian Society of Civil Engineering Annual Conference 2022*, Whistler, BC, Canada, 2022, pp. 839-857.
21. Gasparik, J., "Prove Non Distruttive nell'Edilizia," *Quaderno Didattico AIPND*, Associazione Italiana Prove Non Distruttive, Brescia, Italy, 1992.
22. Alavi, S.A.; Noel, M.; Moradi, F.; and Layssi, H., "Development of a Machine Learning Model for On-Site Evaluation of Concrete Compressive Strength by SonReb," *Journal of Building Engineering*, V. 82, Apr. 2024.
23. Thai, H.-T., "Machine Learning for Structural Engineering: A State-of-the-Art Review," *Structures*, V. 38, Apr. 2022, pp. 448-491.
24. Tapeh, A.T., and Naser, M.Z., "Artificial Intelligence, Machine Learning, and Deep Learning in Structural Engineering: A Scientometrics Review of Trends and Best Practices," *Archives of Computational Methods in Engineering*, V. 30, Jan. 2023, pp. 115-159.
25. Wang, Y.R.; Ngo, L.T.Q.; Shih, Y.F.; Lu, Y.L.; and Chen, Y.M., "Adapting ANNs in SONREB Test to Estimate Concrete Compressive Strength," *Key Engineering Materials*, V. 792, Dec. 2018, pp. 166-169.
26. Shih, Y.-F.; Wang, Y.-R.; Lin, K.-L.; and Chen, C.-W., "Improving Non-Destructive Concrete Strength Tests Using Support Vector Machines," *Materials*, V. 8, No. 10, Oct. 2015, pp. 7169-7178.
27. Sai, G., and Singh, V., "Prediction of Compressive Strength Using Support Vector Regression," *MENDEL Soft Computing Journal*, V. 25, No. 1, June 2019, pp. 51-56.
28. Asteris, P.G., and Mokos, V.G., "Concrete Compressive Strength Using Artificial Neural Networks," *Neural Computing and Applications*, V. 32, No. 15, 2020, pp. 11807-11826.
29. Poorarbabi, A.; Ghasemi, M.; and Moghaddam, M., "Concrete Compressive Strength Prediction Using Neural Networks Based on Non-Destructive Tests and a Self-Calibrated Response Surface Methodology," *Journal of Nondestructive Evaluation*, V. 39, No. 4, Oct. 2020, 11 pp.
30. Ngo, T.Q.L.; Wang, Y.-R.; and Chiang, D.-L. "Applying Artificial Intelligence to Improve On-Site Non-Destructive Concrete Compressive Strength Tests," *Crystals*, V. 11, No. 10, Sept. 2021.
31. Shishegaran, A.; Varaei, H.; Rabczuk, T.; and Shishegaran, G., "High Correlated Variables Creator Machine: Prediction of the Compressive Strength of Concrete," *Computers & Structures*, V. 247, Apr. 2021.
32. Lacroix, F.; Noël, M.; Moradi, F.; Layssi, H.; and Tingson, T., "Nondestructive Condition Assessment of Concrete Slabs with Artificial Defects Using Wireless Impact Echo," *Journal of Performance of Constructed Facilities*, V. 35, No. 6, Aug. 2021.
33. Vu, C.-C.; Plé, O.; Weiss, J.; and Amitrano, D., "Revisiting the Concept of Characteristic Compressive Strength of Concrete," *Construction and Building Materials*, V. 263, Dec. 2020.
34. Rahal, K., "Mechanical Properties of Concrete with Recycled Coarse Aggregate," *Building and Environment*, V. 42, No. 1, Jan. 2007, pp. 407-415.

Selected for reader interest by the editors after independent expert evaluation and recommendation.



Seyed Alireza Alavi is a PhD Student at the University of Ottawa, Ottawa, ON, Canada. His research interests include applying machine learning (ML) methods to find new solutions in structural engineering.



ACI member **Martin Noël** is an Associate Professor at the University of Ottawa. He is Chair of ACI Committee 215, Fatigue of Concrete, and a member of ACI Subcommittees 440-H, FRP-Reinforced Concrete, and 440-I, FRP-Prestressed Concrete. He received his BSc in civil engineering from the University of Manitoba, Winnipeg, MB, Canada, and his PhD in structural engineering from the University of Waterloo, Waterloo, ON, Canada.



ACI member **Hamed Layssi** is a Co-Founder and Structural Engineer at FprimeC Solutions Inc., Richmond Hill, ON, Canada. He is a member of ACI Committee 228, Nondestructive Testing of Concrete. He received his PhD from McGill University, Montreal, QC, Canada.



Farid Moradi is the Co-founder and Principal NDT Engineer at FPrimeC Solutions Inc., bringing over 15 years of research and industrial expertise in the inspection and structural condition assessment of structural systems and foundations. He received his PhD from the University of Sherbrooke, Sherbrooke, QC, Canada, where he focused on pioneering advanced solutions for nondestructive evaluation (NDE) of concrete, with a special focus on developing nonlinear acousto-elastic methods for evaluation of microcracks in concrete elements.

¿Puede la inteligencia artificial mejorar la evaluación no destructiva de la resistencia a la compresión del concreto?

Por Seyed Alireza Alavi, Martin Noël, Hamed Layssi y Farid Moradi

La Inteligencia Artificial (AI) es una herramienta utilizada para interpretar información compleja e incrementar la productividad. La adopción de la inteligencia artificial en aplicaciones dentro de la ingeniería civil ha sido relativamente lenta, pero está comenzando a atraer, cada vez más, la atención a través de la demostración en casos de uso práctico. Este artículo explora la medida en que la inteligencia artificial puede integrarse con el método SonReb para la evaluación no destructiva de la resistencia a compresión del concreto en estructuras de concreto reforzado.

Métodos de prueba no destructivos en sitio

El ACI 228.2R-13⁵ proporciona una visión integral de los métodos no destructivos en sitio para la evaluación de la resistencia a la compresión del concreto, incluida la prueba del martillo de rebote (ASTM C805/C805M-08¹⁰) y mediciones de velocidad de pulso ultrasónico (ASTM C597-16¹¹). La prueba de martillo de rebote es un medio fácil y económico para evaluar la uniformidad del concreto (principalmente cerca de la superficie), mientras las mediciones de velocidad de pulso ultrasónico (UPV) generalmente son utilizadas para evaluar la calidad interna y la integridad de los materiales del concreto por mediciones de la velocidad de transmisión de ondas de esfuerzo compresivo que atraviesan el elemento^{12,13}. Formulaciones teóricas respaldan la existencia de una relación directa entre el módulo de Young y la velocidad de transmisión de ondas, mientras que desde hace mucho tiempo se han establecido relaciones empíricas que vinculan el módulo de Young con la resistencia a la compresión¹⁴⁻¹⁶. Debido a los desafíos en la predicción de la resistencia del concreto a través de Pruebas No Destructivas, que resultan de las variaciones inherentes a las propiedades de los materiales del concreto, a los métodos de NDT, a las relaciones físicas/científicas y la relevancia entre algunos métodos de NDT y la resistencia del concreto, el comité ACI 228 de Pruebas no Destructivas en el Concreto, recomienda el desarrollo de curvas de calibración específicas sitio/material, y un enfoque estadístico para analizar la información recabada. Para estructuras existentes el ACI 228.1R-19¹⁷, recomienda seleccionar entre seis y nueve ubicaciones diferentes para la extracción de núcleos, y se deben obtener un mínimo de dos núcleos por punto para establecer la resistencia a la compresión en el plano (es decir, para establecer una relación de resistencia se requiere un mínimo de 12 núcleos).

La resistencia a la compresión del concreto es comúnmente tomada como un indicador representativo de muchas propiedades del concreto endurecido. Para estructuras existentes, el conocimiento de las propiedades del concreto colado en sitio es vital para la evaluación y rehabilitación del proyecto. Sin embargo, existen retos asociados con los métodos convencionales para la evaluación de la resistencia de éste una vez que la estructura ha sido construida¹⁻⁴. La extracción de núcleos de concreto no siempre es una opción viable para todas las estructuras de concreto (por ejemplo, tanques de concreto, alcantarillado troncal, y líneas de túneles), y la obtención de muestras representativas en estructuras grandes es difícil de obtener.

Los métodos de prueba no destructivos en sitio (NDT) pueden ser correlacionados con la resistencia a la compresión del concreto para reducir el número de núcleos requeridos⁵. El método SonReb⁶ estima la resistencia a la compresión del concreto basado en mediciones combinadas de velocidad de pulso ultrasónico (UPV) y número de rebote (RN). Como en todos los métodos de prueba no destructivos, se requieren curvas de calibración específicas para cada proyecto debido a la naturaleza heterogénea del concreto y diversidad de proporciones en las mezclas⁷⁻⁹; por eso, actualmente no es posible estimar con precisión la resistencia a compresión del concreto de estructuras existentes sin la extracción de núcleos.

La norma EN13791:2019¹⁸ describe un procedimiento que permite el uso de las mediciones del número de rebote sin la extracción de núcleos bajo ciertas condiciones, aunque este enfoque proporciona estimaciones conservadoras en la resistencia del concreto, en lugar de predicciones precisas.

Los métodos de prueba no destructivos se pueden combinar para mejorar su confiabilidad y reducir la sensibilidad a factores como el contenido de humedad, tamaño de agregado, tipo de cemento y grado de refuerzo^{14,19,20}. El método SonReb se ha propuesto como un método simple que presenta una mejora notable con respecto a los métodos de entrada única. Algunos autores han sugerido que los métodos de prueba por velocidad de pulso ultrasónico y número de rebote se ven claramente afectados por potenciales factores de influencia^{6,15,21}, aunque, hasta qué punto esto puede ser así aún está en debate.

Inteligencia Artificial

La inteligencia artificial sobresale en predecir resultados basados en relaciones implícitas identificadas a través de diferentes algoritmos utilizados para interpretar grandes cantidades de datos. Machine Learning (ML) o Aprendizaje Automático (AA) en español, es un subconjunto de la inteligencia artificial que se centra en algoritmos que permiten a las computadoras aprender y tomar decisiones sin ser programadas²²⁻²⁴. La Figura 1 presenta un diagrama de flujo para un modelo típico de supervisión Machine Learning. Dos conjuntos de datos son utilizados en el procedimiento de modelado: el conjunto de datos de entrenamiento y el conjunto de datos de prueba. Aplicando el algoritmo de aprendizaje al conjunto de datos de entrenamiento, la computadora “aprende” relaciones potenciales entre los datos de entrada y salida. Luego, el conjunto de datos de prueba es utilizado para evaluar el rendimiento del modelo, y el procedimiento se repite hasta que el modelo de aprendizaje automático satisface los criterios de evaluación.

Recientemente la inteligencia artificial se ha propuesto como una herramienta para estimar la resistencia a la compresión del concreto basado en el método SonReb²⁵⁻³³. A pesar de que los resultados de estudios previos son prometedores, aún no existe un modelo práctico para su uso en la industria²⁰.

En un artículo por separado, se describe y se compara el desarrollo de un modelo de aprendizaje automático basado en el método SonReb con los enfoques existentes²². Para enfatizar la simplicidad y compatibilidad con las prácticas actuales y considerando la falta de información sobre mezclas de concreto disponible para muchas estructuras existentes, el modelo de aprendizaje automático fue desarrollado únicamente con dos entradas: 1) velocidad de pulso para la prueba directa de velocidad de pulso ultrasónico, y 2) número de rebote para prueba de martillo de rebote horizontal, tal como se muestra en la Figura 2. Para el desarrollo del modelo de aprendizaje automático, una base de datos fue creada utilizando resultados de la literatura publicada, así como de un programa de pruebas con cilindros y cubos de concreto entre 7 y 365 días de edad, representando un amplio rango de diseños de mezcla y resistencia a la compresión. (Los detalles adicionales sobre las bases de datos de aprendizaje y pruebas se presentan en otra parte²².)

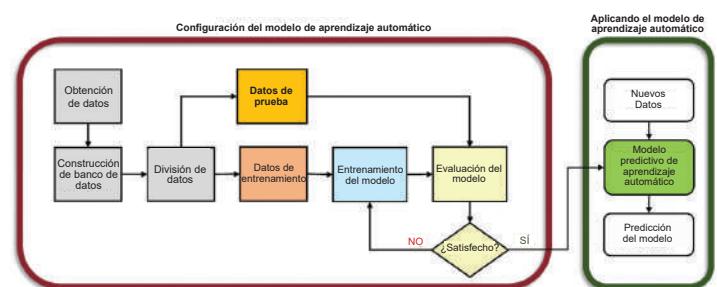


Figura 1: Diagrama de flujo para un modelo de aprendizaje automático (AA) supervisado.

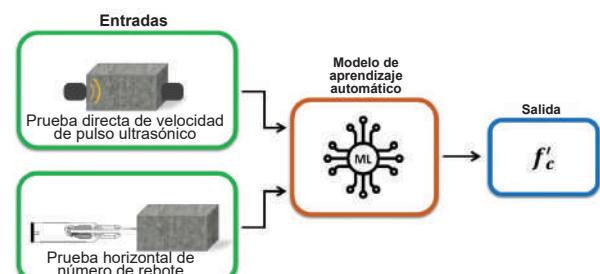


Figura 2: Parámetros del modelo de aprendizaje automático (AA).

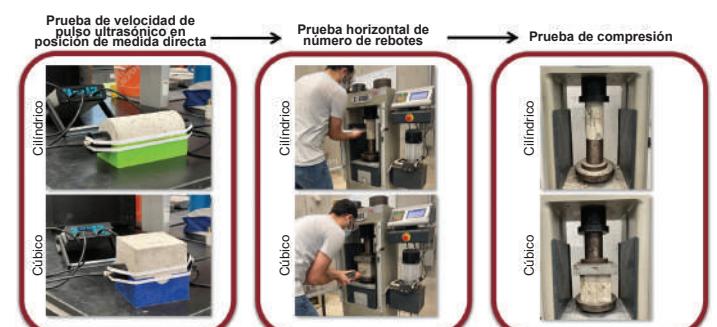


Figura 3: Procedimiento experimental de prueba

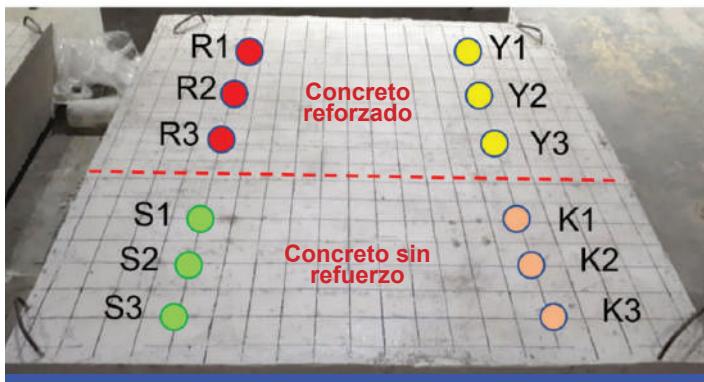


Figura 4: Losa de concreto reforzado con los puntos de prueba marcados (Nota: 1mm = 0.04 in).

El procedimiento de prueba para cada espécimen probado en el laboratorio incluye una prueba de velocidad de pulso ultrasónico en posición de medida directa, seguido por una prueba de martillo de rebote horizontal, y finalmente, la prueba de resistencia a compresión de ambos especímenes, como se muestra en la Figura 3.

El modelo fue desarrollado utilizando el algoritmo del sistema adaptativo de interferencia neurodifusa (ANFIS) en MatLab. Para garantizar un rendimiento sólido del modelo y evitar obtener resultados sesgados, el conjunto de datos de entrenamiento (462 puntos de datos) y el conjunto de datos de prueba (20 puntos de datos) fueron obtenidos de fuentes distintas. El rendimiento del modelo fue comparado con un análisis de regresión lineal y no lineal, así como con ecuaciones existentes en la literatura, y se encontró que proporciona las predicciones más confiables de la resistencia del concreto entre los modelos considerados, con un error absoluto medio inferior al 10%²². Después de desarrollar el modelo de aprendizaje automático, se produjo una aplicación de interfaz gráfica de usuario (GUI), la cual fue utilizada en tres casos de estudio presentados en la siguiente sección. Cada caso de estudio proporcionó datos únicos que no habían sido vistos por el modelo en la fase de entrenamiento. Este enfoque se utilizó para evaluar exhaustivamente el rendimiento del modelo de aprendizaje automático en el mundo real.

Casos de estudio

La exactitud del modelo para aplicaciones en el mundo real se evaluó utilizando tres casos de estudio. En cada caso se siguió una metodología esquemática, incluyendo: 1) ejecución de pruebas de campo no destructivas (velocidad de pulso ultrasónico y número de rebotes); 2) extracción muestras de núcleos de concreto de las mismas áreas seleccionadas para la prueba de resistencia

a la compresión; 3) estimación de la resistencia a la compresión utilizando el modelo de aprendizaje automático y los métodos matemáticos tradicionales, comúnmente conocidos como ecuación de Breysse y ecuación de Gasparik; y 4) comparación de los resultados obtenidos en cada método.

Caso de estudio 1. Losa de concreto reforzado

Una losa de concreto parcialmente reforzada fue fabricada en el laboratorio para un proyecto de investigación independiente³² con dimensiones de 2 x 2 metros (6.5 x 6.5 ft) y 300 mm (12 Plg) de espesor. El concreto para la losa fue suministrado por una empresa local de concreto premezclado. Doce puntos de prueba (mostrados en la Figura 4) fueron seleccionados para este caso de estudio.

La figura 5 presenta los resultados de la prueba. La mejor predicción se obtuvo con el modelo de aprendizaje automático, con un porcentaje de error absoluto promedio (MAPE) de 9.69%, y un coeficiente de variación (COV) de 6.1%. Las ecuaciones de Breysse y Gasparik generaron errores promedios de 28.96% (COV 8.4%) y 36.35% (COV 6.2%), respectivamente, y ambos sobreestimaron consistentemente la resistencia a la compresión de los núcleos de concreto.

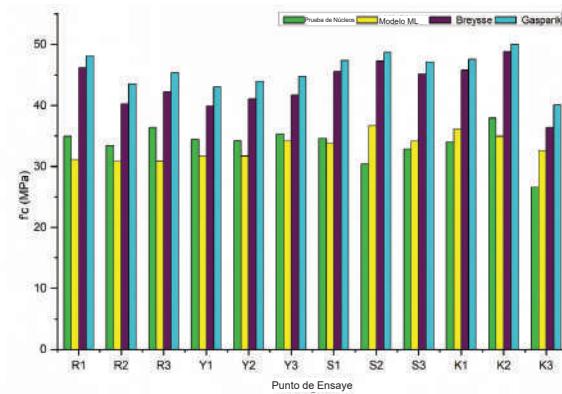


Figura 5: Predicciones de resistencia para el Caso de estudio 1. (Nota: 1MPa = 145 psi)

Caso de estudio 2. Construcción existente de concreto

Un edificio de dos pisos en el campus de una universidad en Canadá requiere evaluar la resistencia a la compresión del concreto como parte de un programa de rehabilitación. Los resultados de la predicción se presentan en la Figura 6. El MAPE del modelo de aprendizaje automático fue de 12.85% (coeficiente de variación igual a 11.4%), mientras

que los errores obtenidos con las ecuaciones de Breysse y Gasparik fueron de 19.79% (COV de 18.9%) y 33.73% (COV de 16.4%) respectivamente. El MAPE para el modelo de aprendizaje automático se reduce a 10.2% si son excluidas dos mediciones en columnas (columna G4Z y columna G4). Los resultados sugieren que el modelo funcionó mejor para losas planas y secciones de muro que para columnas, aunque la razón de esta diferencia aún se encuentra bajo investigación.

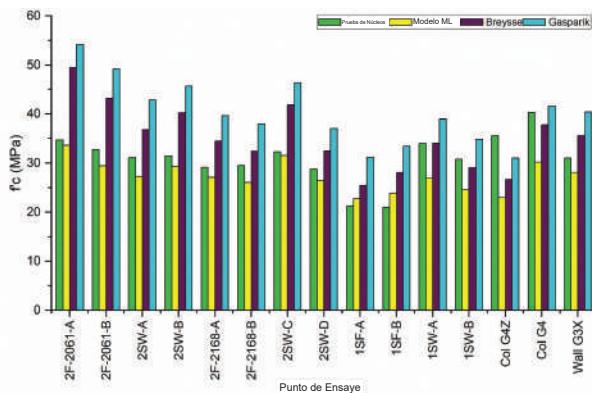


Figura 6: Predicciones de resistencia para el caso de estudio 2.
(Nota: 1MPa = 145 psi)

Caso de estudio 3. Cimentación elevada

Un error de construcción en la cimentación elevada de un silo de almacenamiento en una instalación minera dio como resultado una consolidación deficiente del concreto y una formación de paneles moderados a severos alrededor de la capa inferior del acero de refuerzo, y la zona dio un rendimiento similar (con errores promedio de 33.33% y 32.9%, con coeficientes de variación de 11% a 20%, respectivamente).

Discusión

El concreto es un material heterogéneo y diverso. Los valores de resistencia a la compresión obtenidos ensayando cilindros de una misma mezcla de concreto fácilmente pueden variar en un 10% o más^{33,34}. En este contexto, obtener un porcentaje de exactitud del 100% para cualquier modelo no es realista; garantizar la coherencia y confiabilidad de las predicciones, así como identificar posibles limitaciones del modelo, es un objetivo más importante y alcanzable. Este estudio presenta evidencia de que la inteligencia artificial es una herramienta que puede contribuir a este esfuerzo. Y de la misma manera que todas las herramientas son utilizadas, se requiere criterios de ingeniería para interpretar los resultados.

El modelo de inteligencia artificial presentado en este artículo conserva la simplicidad del método SonReb manteniendo solo dos parámetros de entrada (velocidad de pulso ultrasónico y número de rebote)²². Los resultados de este enfoque incluyen mayor disponibilidad de información para el entrenamiento del modelo, así como una amplia aplicabilidad debido a que no se requiere información sobre el diseño de la mezcla del concreto, condiciones de curado, o edad del concreto. Como se demuestra en los casos de estudio presentados, se obtuvieron predicciones razonablemente buenas para concreto sano y superficies planas con cantidades de refuerzo bajas y moderadas. Se obtuvieron excepciones notables para las columnas del caso 2 (posiblemente debidas al alto grado de refuerzo o efectos geométricos) y para concreto dañado o defectuoso en el caso de estudio 3. En ambos casos, el modelo subestima la resistencia actual del concreto en un promedio de

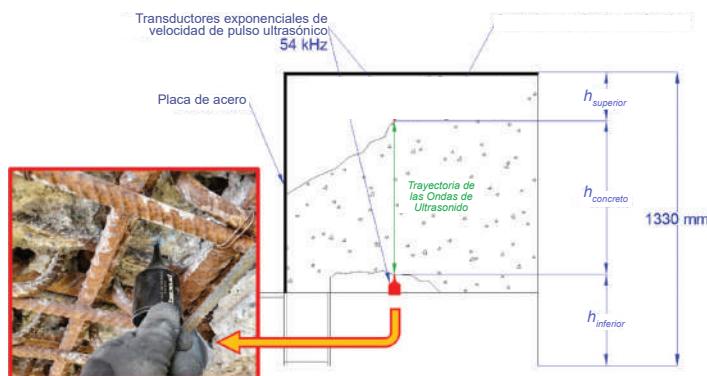


Figura 7: Pruebas de velocidad de pulso ultrasónico para el caso de estudio 3. (Nota: 1 mm = 0.04 in.)

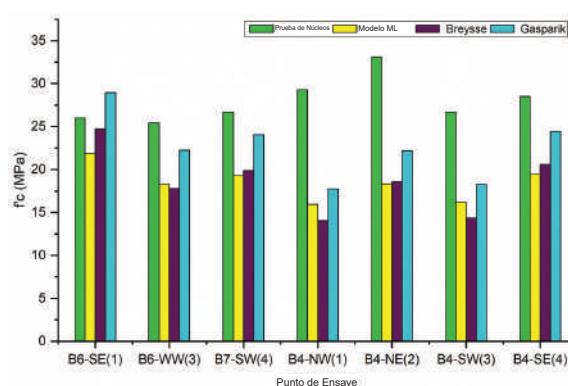


Figura 8: Predicciones de resistencia para el caso de estudio 3.
(Nota: 1MPa = 145 psi)

30% aproximadamente (esto es, las estimaciones fueron conservadoras). Como se justifica una mayor investigación sobre los efectos de la congestión en el refuerzo y la geometría de los miembros en las mediciones de las pruebas no destructivas y los resultados del modelo asociado, no es sorprendente que el concreto de mala calidad con panal visible correspondiera con el error promedio más grande en la predicción de la resistencia a la compresión, ya que los datos de entrenamiento fueron obtenidos para especímenes de concreto sanos. Esto sirve para destacar el rol de los ingenieros en la interpretación de los resultados obtenidos de herramientas como la inteligencia artificial. A medida que los modelos de inteligencia artificial se vuelven más sólidos y se dispone de bases de datos de capacitación más grandes, sus capacidades también aumentarán; si bien la inteligencia artificial puede aumentar nuestra productividad, los ingenieros seguirán desempeñando un papel vital en la evaluación del estado de las estructuras en el futuro previsible.

Actualmente se está llevando a cabo un trabajo en curso para investigar si la precisión del modelo se puede mejorar aún más considerando parámetros de entrada adicionales, como la geometría (que inicialmente se ignoró a pesar de su efecto conocido sobre la resistencia del concreto y las mediciones de los métodos de prueba no destructivos), la edad y los parámetros básicos de diseño de la mezcla. El desafío obvio es que, para considerar más parámetros, el tamaño de la base de datos en consecuencia debe aumentar. Recopilar datos suficientes de buena calidad y filtrar valores atípicos o resultados de mala calidad es una tarea compleja; sin embargo, como se ve en la proliferación de la inteligencia artificial en otras disciplinas, el resultado puede ser bastante poderoso. En general, los resultados obtenidos hasta la fecha son alentadores y sugieren que la inteligencia artificial se puede adaptar para resolver desafíos clave en la industria de la construcción cuando se dispone de datos suficientes.

Finalmente, no se debe pasar por alto la importancia de los conceptos estadísticos de nivel de confianza para interpretar las predicciones del modelo de aprendizaje automático, como recomienda ACI 228.1R-19¹⁷ para todos los casos. Este es el tema del trabajo continuo de los autores y es un paso esencial para evaluar y aplicar los resultados del modelo.

Referencias

1. Breysse, D., and Balayssac, J.-P., *Non-Destructive In Situ Strength Assessment of Concrete*, Springer, 2021, 381 pp.
2. Pucinotti, R., “Reinforced Concrete Structure: Non-Destructive In-Situ Strength Assessment of Concrete,” *Construction and Building Materials*, V. 75, Jan. 2015, pp. 331-341.
3. Breysse, D.; Soutsos, M.; Felicetti, R.; Krause, M.; Lataste, J.-F.; and Moczko, A., “How to Improve the Quality of Concrete Assessment by Combining Several NDT Measurements,” *Proceedings of International Symposium on Non-Destructive Testing in Civil Engineering*, 2009, 8 pp.
4. Na, U.J.; Park, T.W.; Feng, M.Q.; and Chung, L., “Neuro-Fuzzy Application for Concrete Strength Prediction Using Combined Non-Destructive Tests,” *Magazine of Concrete Research*, V. 61, No. 4, May 2009, pp. 245-256.
5. ACI Committee 228, “Report on Nondestructive Test Methods for Evaluation of Concrete in Structures (ACI 228.2R-13),” American Concrete Institute, Farmington Hills, MI, 2013, 82 pp.
6. RILEM, “Draft Recommendation for In Situ Concrete Strength Determination by Combined Non-Destructive Methods,” *Materials and Structures*, V. 26, Jan. 1993, pp. 43-49.
7. Kouddane, B.; Sbartaï, Z.M.; Alwash, M.; Ali-Benyahia, K.A.; Elachachi, S.M.; Lamdouar, N.; and Kenai, S., “Assessment of Concrete Strength Using the Combination of NDT—Review and Performance Analysis,” *Applied Sciences*, V. 12, No. 23, Nov. 2022.
8. Bolborea, B.; Dan, S.; Baeră, C.; Gruin, A.; Enache, F.; and Perianu, I.A., “Study Regarding the Evaluation of Prediction Models for Determining the Concrete Compressive Strength Using Non-Destructive Testing (NDT) Data: Validation Stage,” *Solid State Phenomena*, V. 332, May 2022, pp. 173-181.
9. Cristofaro, M.T.; Viti, S.; and Tanganelli, M., “New Predictive Models to Evaluate Concrete Compressive Strength Using the SonReb Method,” *Journal of Building Engineering*, V. 27, Jan. 2020.
10. ASTM C805/C805M-08, “Standard Test Method for Rebound Number of Hardened Concrete,” ASTM International, West Conshohocken, PA, 2008, 3 pp.
11. ASTM C597-16, “Standard Test Method for Pulse Velocity Through Concrete,” ASTM International, West Conshohocken, PA, 2016, 4 pp.
12. Malek, J., and Kaouther, M., “Destructive and Non-Destructive Testing of Concrete Structures,” *Jordan Journal of Civil Engineering*, V. 8, No. 4, 2014, pp. 432-441.
13. Poorarbabi, A.; Ghasemi, M.R.; and Azhdari Moghaddam, M., “Conversion Factors Between Non-Destructive Tests of Cubic and Cylindrical Concrete Specimens,” *AUT Journal of Civil Engineering*, V. 5, No. 1, 2021, pp. 3-16.
14. Breysse, D., “Nondestructive Evaluation of Concrete Strength: An Historical Review and a New Perspective

- by Combining NDT Methods," *Construction and Building Materials*, V. 33, Aug. 2012, pp. 139-163.
15. Rajabi, A.M.; Omidi Moaf, F.; and Abdolgader, H.S., "Evaluation of Mechanical Properties of Two-Stage Concrete and Conventional Concrete Using Nondestructive Tests," *Journal of Materials in Civil Engineering*, V. 32, No. 7, July 2020.
 16. Agunwamba, J., and Adagba, T., "A Comparative Analysis of the Rebound Hammer and Ultrasonic Pulse Velocity in Testing Concrete," *Nigerian Journal of Technology*, V. 31, No. 1, Mar. 2012, pp. 31-39.
 17. ACI Committee 228, "Report on Methods for Estimating In-Place Concrete Strength (ACI 228.1R-19)," American Concrete Institute, Farmington Hills, MI, 2019, 48 pp.
 18. "EN 13791:2019: Assessment of In-Situ Compressive Strength in Structures and Precast Concrete Components," CEN-CENELEC Management Centre, Brussels, Belgium, 2019, 41 pp.
 19. Kayed, A.R., "The Strength of Concrete in Existing RC Structures," MS thesis, Politecnico di Torino, Turin, Italy, July 2021, 67 pp.
 20. Alavi, S.A., and Noël, M., "Challenges for the Development of Artificial Intelligence Models to Predict the Compressive Strength of Concrete Using Non-Destructive Tests: A Review," *Proceedings of the Canadian Society of Civil Engineering Annual Conference 2022*, Whistler, BC, Canada, 2022, pp. 839-857.
 21. Gasparik, J., "Prove Non Distruttive nell'Edilizia," Quaderno Didattico AIPND, Associazione Italiana Prove Non Distruttive, Brescia, Italy, 1992.
 22. Alavi, S.A.; Noel, M.; Moradi, F.; and Layssi, H., "Development of a Machine Learning Model for On-Site Evaluation of Concrete Compressive Strength by SonReb," *Journal of Building Engineering*, V. 82, Apr. 2024.
 23. Thai, H.-T., "Machine Learning for Structural Engineering: A State-of-the-Art Review," *Structures*, V. 38, Apr. 2022, pp. 448-491.
 24. Tapeh, A.T., and Naser, M.Z., "Artificial Intelligence, Machine Learning, and Deep Learning in Structural Engineering: A Scientometrics Review of Trends and Best Practices," *Archives of Computational Methods in Engineering*, V. 30, Jan. 2023, pp. 115-159.
 25. Wang, Y.R.; Ngo, L.T.Q.; Shih, Y.F.; Lu, Y.L.; and Chen, Y.M., "Adapting ANNs in SONREB Test to Estimate Concrete Compressive Strength," *Key Engineering Materials*, V. 792, Dec. 2018, pp. 166-169.
 26. Shih, Y.-F.; Wang, Y.-R.; Lin, K.-L.; and Chen, C.-W., "Improving Non-Destructive Concrete Strength Tests Using Support Vector Machines," *Materials*, V. 8, No. 10, Oct. 2015, pp. 7169-7178.
 27. Sai, G., and Singh, V., "Prediction of Compressive Strength Using Support Vector Regression," *MENDEL Soft Computing Journal*, V. 25, No. 1, June 2019, pp. 51-56.
 28. Asteris, P.G., and Mokos, V.G., "Concrete Compressive Strength Using Artificial Neural Networks," *Neural Computing and Applications*, V. 32, No. 15, 2020, pp. 11807-11826.
 29. Poorarbabi, A.; Ghasemi, M.; and Moghaddam, M., "Concrete Compressive Strength Prediction Using Neural Networks Based on Non-Destructive Tests and a Self-Calibrated Response Surface Methodology," *Journal of Nondestructive Evaluation*, V. 39, No. 4, Oct. 2020, 11 pp.
 30. Ngo, T.Q.L.; Wang, Y.-R.; and Chiang, D.-L. "Applying Artificial Intelligence to Improve On-Site Non-Destructive Concrete Compressive Strength Tests," *Crystals*, V. 11, No. 10, Sept. 2021.
 31. Shishegaran, A.; Varaei, H.; Rabczuk, T.; and Shishegaran, G., "High Correlated Variables Creator Machine: Prediction of the Compressive Strength of Concrete," *Computers & Structures*, V. 247, Apr. 2021.
 32. Lacroix, F.; Noël, M.; Moradi, F.; Layssi, H.; and Tingson, T., "Nondestructive Condition Assessment of Concrete Slabs with Artificial Defects Using Wireless Impact Echo," *Journal of Performance of Constructed Facilities*, V. 35, No. 6, Aug. 2021.
 33. Vu, C.-C.; Plé, O.; Weiss, J.; and Amitrano, D., "Revisiting the Concept of Characteristic Compressive Strength of Concrete," *Construction and Building Materials*, V. 263, Dec. 2020.
 34. Rahal, K., "Mechanical Properties of Concrete with Recycled Coarse Aggregate," *Building and Environment*, V. 42, No. 1, Jan. 2007, pp. 407-415.

Seyed Alireza Alavi es estudiante de Doctorado en Filosofía en la Universidad de Ottawa, Ottawa, ON, Canadá. Sus intereses incluyen la aplicación de métodos de aprendizaje automático (ML) para encontrar nuevas soluciones en ingeniería estructural.



Martin Noël es miembro del ACI. Es profesor de la Universidad de Ottawa. Es presidente del Comité 215 del ACI, Fatiga del Concreto, y miembro de los subcomités 440-H, Concreto Reforzado con FRP, y el comité 440-I, Concreto Pretensado con FRP. Estudió su licenciatura en Ingeniería Civil por la Universidad de Manitoba, Winnipeg, MB, Canadá, y su doctorado en Ingeniería Estructural por la Universidad de Waterloo, Waterloo, ON, Canadá.



Hamed Layssi es miembro del ACI. Es cofundador e ingeniero estructural de FprimeC Solutions Inc., Richmond Hill, ON Canadá. Es miembro del comité ACI 228, Ensayos no Destructivos del Concreto. Estudió un Doctorado en Filosofía por la Universidad de McGill, Montreal, QC, Canadá.



Farid Moradi es cofundador y principal ingeniero en pruebas no destructivas de FPrimeC Solutions Inc., contando con más de 15 años de experiencia e investigación en la inspección y asesoramiento en el estado estructural de sistemas estructurales y cimentaciones. Estudió un Doctorado en Filosofía en la Universidad de Sherbrooke, Sherbrooke, QC, Canadá, donde se enfocó en ser pionero en soluciones avanzadas para la evaluación no destructiva del concreto, con un enfoque especial en el desarrollo de métodos acústico-elásticos no lineales para la evaluación de microfisuras en elementos de concreto.



Título original en inglés:
Can Artificial Intelligence Improve Nondestructive Evaluation of Concrete Strength?

La traducción de este artículo correspondió al Capítulo de México Noroeste

Traductor:
Jesús Omar Montaño Montaño
Estudiante Ing. Civil
Universidad de Sonora



Revisor Técnico:
Ing. Óscar Ramírez Arvizu

