

FACULTAD DE INGENIERÍA

Carrera de **INGENIERÍA CIVIL**

“PREDICCIÓN DE LA RESISTENCIA A LA
COMPRESIÓN DE CONCRETO DE 210 kg/cm² y
175 kg/cm² CON REDES NEURONALES
ARTIFICIALES, CAJAMARCA 2022”

Tesis para optar el título profesional de:

Ingeniero Civil

Autores:

Christian Diego Aristizaval Albarran

Khoraly del Alba Intor Villatty

Asesor:

Mg. Ing. Henry Josué Villanueva Bazán

<https://orcid.org/0000-0001-8814-6079>

Cajamarca - Perú

JURADO EVALUADOR

Jurado 1	LIZBETH MILAGROS MERMA GALLARDO	40012838
Presidente(a)	Nombre y Apellidos	Nº DNI

Jurado 2	TULIO EDGAR GUILLÉN SHEEN	26676774
	Nombre y Apellidos	Nº DNI

Jurado 3	JANE ELIZABETH ALVAREZ LLANOS	26704582
	Nombre y Apellidos	Nº DNI

INFORME DE SIMILITUD

TESIS

INFORME DE ORIGINALIDAD

12%

INDICE DE SIMILITUD

12%

FUENTES DE INTERNET

7%

PUBLICACIONES

9%

TRABAJOS DEL
ESTUDIANTE

ENCONTRAR COINCIDENCIAS CON TODAS LAS FUENTES (SOLO SE IMPRIMIRÁ LA FUENTE SELECCIONADA)

22%

★ hdl.handle.net

Fuente de Internet

Excluir citas

Apagado

Excluir coincidencias < 1%

Excluir bibliografía

Apagado

Tabla de contenido

JURADO CALIFICADOR	2
INFORME DE SIMILITUD	3
DEDICATORIA	4
AGRADECIMIENTO	5
TABLA DE CONTENIDO	6
ÍNDICE DE TABLAS	7
ÍNDICE DE FIGURAS	9
ÍNDICE DE ECUACIONES	11
RESUMEN	12
CAPÍTULO I: INTRODUCCIÓN	13
1.1. Realidad problemática	13
1.2. Formulación del problema	28
1.3. Objetivos	28
1.4. Hipótesis	29
CAPÍTULO II: METODOLOGÍA	30
CAPÍTULO III: RESULTADOS	48
CAPÍTULO IV: DISCUSIÓN Y CONCLUSIONES	80
REFERENCIAS	87
ANEXOS	94

ÍNDICE DE TABLAS

Tabla 1 Número de muestras por edad y resistencia de diseño	31
Tabla 2 Operacionalización de variables.....	32
Tabla 3 Ensayos realizados para los diseños de mezcla y sus respectivas normativas.....	33
Tabla 4 Resistencias f'c esperadas por edad, para probetas.	38
Tabla 5 Parámetros de entrada y salida de la red neuronal artificial	40
Tabla 6 Características de la RNA seleccionadas.....	44
Tabla 7 Cantidad de materiales según diseño de mezcla para 210 kg/cm ²	46
Tabla 8 Cantidad de materiales según diseño de mezcla para 175 kg/cm ²	46
Tabla 9 Descripción estadística de la base de datos.....	58
Tabla 10 Resultado de la búsqueda de hiperparámetros.....	60
Tabla 11 Valores RMSE, R ² y r para el enteramiento y prueba de RNA.	60
Tabla 12 Carga máxima de probetas a los 7 días – 175 kg/cm ²	65
Tabla 13 Carga máxima de probetas a los 14 días - 175 kg/cm ²	65
Tabla 14 Carga máxima de probetas a los 28 días - 175 kg/cm ²	66
Tabla 15 Carga máxima de probetas a los 7 días - 210 kg/cm ²	66
Tabla 16 Carga máxima de probetas a los 14 días - 210 kg/cm ²	67
Tabla 17 Carga máxima de probetas a los 28 días - 210 kg/cm ²	67
Tabla 18 Resistencia a la compresión de probetas a los 7 días para 175 kg/cm ²	68
Tabla 19 Resistencia a la compresión de probetas a los 14 días para 175 kg/cm ²	68
Tabla 20 Resistencia a la compresión de probetas a los 28 días para 175 kg/cm ²	69
Tabla 21 Resistencia a la compresión de probetas a los 7 días para 210 kg/cm ²	69
Tabla 22 Resistencia a la compresión de probetas a los 14 para 210 kg/cm ²	70
Tabla 23 Resistencia a la compresión de probetas a los 28 días para 210 kg/cm ²	70
Tabla 24 Resistencia predichas por la RNA para 175 y 210 kg/cm ²	71
Tabla 25 Diferencias y error de f'c real y f'c pronosticado a 7 días para 175 kg/cm ²	71
Tabla 26 Diferencias y error de f'c real y f'c pronosticado a 14 días para 175 kg/cm ²	72
Tabla 27 Diferencias y error de f'c real y f'c pronosticado a 28 días para 175 kg/cm ²	73
Tabla 28 Valores promedio f'c real y f'c pronosticada para 175 kg/cm ²	74

Tabla 29 Diferencia y error de $f'c$ real y $f'c$ pronosticada a 7 días para 210 kg/cm ²	75
Tabla 30 Diferencia y error de $f'c$ real y $f'c$ pronosticada a 14 días para 210 kg/cm ²	76
Tabla 31 Diferencia y error de $f'c$ real y $f'c$ pronosticada a 28 días para 210 kg/cm ²	77
Tabla 32 Valores promedio $f'c$ real y $f'c$ pronosticada para 210 kg/cm ²	78

ÍNDICE DE FIGURAS

Figura 1 Difusión de las RNA en el mundo.....	15
Figura 2 Arquitectura de una red neuronal artificial.....	23
Figura 3 Validación cruzada.....	25
Figura 4 Diagrama de la metodología empleada.....	31
Figura 5 Ficha de recolección de datos de diseño de mezcla y resistencia a la compresión.....	34
Figura 6 Protocolo: Resistencia a la Compresión de Testigos Cilíndricos.....	35
Figura 7 Técnicas de recolección de datos.....	36
Figura 8 Análisis de datos cuantitativos según el tipo de investigación.....	37
Figura 9 Datos en formato csv para ser ingresados a la RNA.....	39
Figura 10 Proceso de tratamiento de datos durante el entrenamiento de la red neuronal artificial (RNA).....	43
Figura 11 Diagrama de flujo propuesto para la red neuronal artificial.....	45
Figura 12 Histograma de las variables de entrada para RNA.....	58
Figura 13 Gráfico de cajas y bigotes por cantidad de días para un f'c de 175 Kg/cm ²	59
Figura 14 Gráfico de cajas y bigotes por cantidad de días para un f'c de 210 Kg/cm ²	59
Figura 15 Gráfico de dispersión de la etapa de entrenamiento.....	61
Figura 16 Comparación entre los valores reales y predichos para concreto f'c = 175 kg/cm ² en la etapa de entrenamiento, primera mitad de los datos.....	62
Figura 17 Comparación entre los valores reales y predichos para concreto f'c = 210 Kg/cm ² en la etapa de entrenamiento.....	62
Figura 18 <i>Comparación entre los valores reales y predichos para concreto f'c = 210 kg/cm² en la etapa de entrenamiento, segunda mitad de los datos</i>	63
Figura 19 Gráfico de dispersión de la etapa de entrenamiento.....	63
Figura 20 Comparación entre los valores reales y predichos para concreto f'c = 175 kg/cm ² en la etapa de prueba.....	64
Figura 21 Comparación entre los valores reales y predichos para concreto f'c = 210 kg/cm ² en la etapa de prueba.....	64
Figura 22 Comparación del f'c real y predicho para concreto f'c=175 kg/cm ² a los 7 días.....	72
Figura 23 Comparación del f'c real y predicho para concreto f'c=175 kg/cm ² a los 14 días.....	73

Figura 24	Comparación del f _c real y predicho para concreto f _c =175 kg/cm ² a los 28 días.	74
Figura 25	Gráfico de f _c real vs f _c pronosticada para 175 kg/cm ²	75
Figura 26	Comparación del f _c real y predicho para concreto f _c =210 kg/cm ² a los 7 días	76
Figura 27	Comparación del f _c real y predicho para concreto f _c =210 kg/cm ² a los 14 días	77
Figura 28	Comparación del f _c real y predicho para concreto f _c =210 kg/cm ² a los 28 días	78
Figura 29	Gráfico de f _c real vs f _c pronosticada para 210 kg/cm ²	79

ÍNDICE DE ECUACIONES

Ecuación 1 Coeficiente de Determinación (R^2):.....	25
Ecuación 2 Coeficiente de correla de Pearson (r):.....	26
Ecuación 3 Error cuadrático medio (RMSE):	27
Ecuación 4 Error Absoluto:.....	27
Ecuación 5 Error relativo:	27

RESUMEN

La investigación "Predicción de la resistencia a la compresión de concreto de 210 y 175 kg/cm² con redes neuronales artificiales" tuvo como objetivo determinar la precisión de la predicción de una red neuronal artificial (RNA) para determinar la resistencia a la compresión de concreto por medio del análisis estadístico de los datos de resistencia predichos en comparación con los obtenidos en laboratorio. Para ello, se creó una base de datos históricos de diseños de mezcla y se programó una RNA en Python capaz de predecir la resistencia a la compresión de ambos tipos de concreto. Luego, se elaboraron probetas de concreto de 15 x 30 cm para cada tipo de resistencia, siendo 54 en total y se determinó su resistencia a la compresión a los 7, 14 y 28 días mediante ensayos de laboratorio. Los resultados mostraron que la RNA tiene un error máximo promedio de 4.3 % en los 28 días para concreto de 175 Kg/cm² y de 4.7 % para 7 días para un concreto con diseño 210 kg/cm²

PALABRAS CLAVES: Resistencia a la compresión, redes neuronales, predicción, ingeniería civil, nuevas tecnologías.

NOTA

El contenido de la investigación no se encuentra disponible en **acceso abierto**, por determinación de los propios autores amparados en el Texto Integrado del Reglamento RENATI, artículo 12.

REFERENCIAS

- Ababneh, A., Alhassan, M., & Abu-Haifa, M. (2020). Predicting the contribution of recycled aggregate concrete to the shear capacity of beams without transverse reinforcement using artificial neural networks. *Case Studies in Construction Materials*, 13, e00414. <https://doi.org/10.1016/j.cscm.2020.e00414>
- Achedad, C. P., & Giménez, O. L. (2011). *Ingeniería de Organización* (1a ed.). Díaz de Santos.
- Alcívar, W. S., Bravo, Y. M., Pavón, C., Solórzano, E., & Palacios, U. T. de M. (2020). Influencia del curado en obra sobre la resistencia a la compresión del concreto. *Revista Técnica De La Facultad De Ingeniería Universidad Del Zulia*, ve2020(2), 19–25. <https://doi.org/10.22209/rt.ve2020n2a03>
- Alemán Morales, D. (2017). Técnicas de inteligencia artificial aplicadas a problemas de ingeniería civil. *Revista de Arquitectura e Ingeniería*, 11(3), 1–7. <https://dialnet.unirioja.es/servlet/articulo?codigo=8315938%0Ahttps://www.redalyc.org/articulo.oa?id=193955164005>
- American society for testing and materials (astm). (2018). Astm C39. En *Standard Test Method for Compressive Strength of Cylindrical Concrete Specimens1: Vol. i* (pp. 1–14).
- Aragón Izquierdo, P. (2011). *Análisis de costes realizado sobre los ensayos realizados en laboratorios de control de edificación sobre hormigón y acero* (p. 132). Universidad Politécnica de València. [https://m.riunet.upv.es/bitstream/handle/10251/18447/Patricia Aragón.pdf?sequence=2&isAllowed=y](https://m.riunet.upv.es/bitstream/handle/10251/18447/PatriciaAragón.pdf?sequence=2&isAllowed=y)
- Arana, R. (2015). *Diseño de Mezcla*. Introducción a la Ingeniería. <https://es.slideshare.net/rogerjob/dosificacion-o-diseo-de-mezclas-del-concreto>
- Ashrafian, A., Shokri, F., Taheri Amiri, M. J., Yaseen, Z. M., & Rezaie-Balf, M. (2020). Compressive strength of Foamed Cellular Lightweight Concrete simulation: New development of hybrid artificial intelligence model. *Construction and Building Materials*, 230, 117048. <https://doi.org/10.1016/j.conbuildmat.2019.117048>

- Asri, Y. el, Aicha, M. ben, Zaher, M., & Alaoui, A. H. (2022). Prediction of compressive strength of self-compacting concrete using four machine learning technics. *Materials Today: Proceedings*, 57, 859–866. <https://doi.org/10.1016/j.matpr.2022.02.487>
- Basha, S. M., & Rajput, D. S. (2019). Survey on Evaluating the Performance of Machine Learning Algorithms: Past Contributions and Future Roadmap. En *Deep Learning and Parallel Computing Environment for Bioengineering Systems* (pp. 153–164). Elsevier. <https://doi.org/10.1016/B978-0-12-816718-2.00016-6>
- Bianchini, S., Müller, M., & Pelletier, P. (2022). Artificial intelligence in science: An emerging general method of invention. *Research Policy*, 51(10), 104604. <https://doi.org/10.1016/j.respol.2022.104604>
- Bilim, C., Atiş, C. D., Tanyildizi, H., & Karahan, O. (2009). Predicting the compressive strength of ground granulated blast furnace slag concrete using artificial neural network. *Advances in Engineering Software*, 40(5), 334–340. <https://doi.org/10.1016/j.advengsoft.2008.05.005>
- Blake, R. W., Mathew, R., George, A., & Papakostas, N. (2021). Impact of Artificial Intelligence on Engineering: Past, Present and Future. *Procedia CIRP*, 104, 1728–1733. <https://doi.org/10.1016/j.procir.2021.11.291>
- Boudali, S., Abdulsalam, B., Rafiean, A. H., Poncet, S., Soliman, A., & ElSafty, A. (2021). Influence of Fine Recycled Concrete Powder on the Compressive Strength of Self-Compacting Concrete (SCC) Using Artificial Neural Network. *Sustainability*, 13(6), 3111. <https://doi.org/10.3390/su13063111>
- Brunarski, L., & Dohojda, M. (2016). An approach to in-situ compressive strength of concrete. *Bulletin of the Polish Academy of Sciences: Technical Sciences*, 64(4), 687–695. <https://doi.org/10.1515/BPASTS-2016-0078>
- Caicedo B, E. F., & López S, J. A. (2017). Una aproximación práctica a las redes neuronales artificiales. En *Una aproximación práctica a las redes neuronales artificiales* (Edición Di). Programa Editorial Universidad del Valle. <https://doi.org/10.25100/peu.64>
- Chou, J. S., Tsai, C. F., Pham, A. D., & Lu, Y. H. (2014). Machine learning in concrete strength simulations: Multi-nation data analytics. *Construction and Building Materials*, 73, 771–780. <https://doi.org/10.1016/j.conbuildmat.2014.09.054>

- Churches, A. (2009). Bloom's Taxonomy Blooms Digitally | Edorigami. *Edorigami*, 1(September), 76. <https://bit.ly/3Rje0Db>
- Conklin, J. (2014). A Taxonomy for Learning, Teaching, and Assessing: A Revision of Bloom's Taxonomy of Educational Objectives. *Educational Horizons*, 83(44), 167–169. <https://doi.org/10.12816/0007239>
- Denning, P. J., & Lewis, T. G. (2016). Exponential laws of computing growth. *Communications of the ACM*, 60(1), 54–65. <https://doi.org/10.1145/2976758>
- Dirección de Normalización - INACAL. (2015). *NTP 339.034*.
- Espinoza Freire, E. E. (2018). Las variables y su operacionalización en la investigación educativa. parte I. *Revista pedagógica de la Universidad de Cienfuegos*, 14(65), 39–49.
- Franganillo, J. (2022). Contenido generado por inteligencia artificial: oportunidades y amenazas AI-generated content: opportunities and threats. *ThinkEPI*, 1–17. <https://franganillo.es/ia.pdf>
- García-García, J. A., Reding-Bernal, A., & López-Alvarenga, J. C. (2013). Cálculo del tamaño de muestra. *Investigación en Educación Médica*, 2, 217–224.
- Gholampour, A., Gandomi, A. H., & Ozbakkaloglu, T. (2017). New formulations for mechanical properties of recycled aggregate concrete using gene expression programming. *Construction and Building Materials*, 130, 122–145. <https://doi.org/10.1016/j.conbuildmat.2016.10.114>
- Girish, M. G., Shetty, K. K., & Rao Raja, A. (2018). Self-Consolidating Paving Grade Geopolymer Concrete. *IOP Conference Series: Materials Science and Engineering*, 431(9), 092006. <https://doi.org/10.1088/1757-899X/431/9/092006>
- Golafshani, E. M., & Behnood, A. (2018). Application of soft computing methods for predicting the elastic modulus of recycled aggregate concrete. *Journal of Cleaner Production*, 176, 1163–1176. <https://doi.org/10.1016/j.jclepro.2017.11.186>
- González, L., Guerrero, A., Delvastro, S., & Will, A. (2012). Red neuronal artificial para estimar la resistencia a compresión, en concretos fibro-reforzados con polipropileno. *Ventana Informativa*, 26, 11–28.

<http://revistasum.umanizales.edu.co/ojs/index.php/ventanainformatica/article/viewFile/217/267>

- González Salcedo, L. O., Guerrero Zúñiga, A. P., Delvasto Arjona, S., & Will, A. L. E. (2015). Elaboración de un modelo evolutivo híbrido de algoritmos genéticos y redes neuronales artificiales para dosificaciones de mezclas de concreto reforzadas con fibras metálicas. *Revista de Ingeniería*, 43, 46–54.
<https://doi.org/10.16924/riua.v0i43.874>
- Guerrero, A., & Díaz, G. (2007). *Introducción de Errores en la Medición*. (ITM, Ed.; 1a ed.).
- Guillen, Y., Soto, J., & Soto, F. (2013). Evaluación del comportamiento de las probetas cilíndricas de dimensiones 10, 6 × 21, 2 cm para el control de calidad del concreto. *Ingenieria UC*, 35–44.
- Hammoudi, A., Moussaceb, K., Belebchouche, C., & Dahmoune, F. (2019). Comparison of artificial neural network (ANN) and response surface methodology (RSM) prediction in compressive strength of recycled concrete aggregates. *Construction and Building Materials*, 209, 425–436. <https://doi.org/10.1016/j.conbuildmat.2019.03.119>
- Haripriya, S., Rajesh, B., Sudarshan, D. S., & Bhaskar, B. (2020). Strength Characteristics of Recycled Aggregate Concrete by Ann. *International Journal of Innovative Technology and Exploring Engineering*, 9(3), 1210–1214.
<https://doi.org/10.35940/ijitee.C8624.019320>
- Hernández Sampieri, R., Fernández Collado, C., & Baptista Lucio, M. del P. (2014). *Metodología de la investigación* (M. Á. Castellanos Toledo, Ed.; 6a ed.). McGraw-Hill Interamericana de España.
- Incio Flores, F. A., Capuñay Sanchez, D. L., Estela Urbina, R. O., Valles Coral, M. Á., Vergara Medrano, E. E., & Elera Gonzales, D. G. (2021). Inteligencia artificial en educación: una revisión de la literatura en revistas científicas internacionales. *Apuntes Universitarios*, 12(1), 353–372. <https://doi.org/10.17162/au.v12i1.974>
- Jiménez González, L. L. (2020). Investigacion cuantitativa. *Convergence Tech Revista Científica*, 4(1), 59–68.
- Khademi, F., Jamal, S. M., Deshpande, N., & Londhe, S. (2016). Predicting strength of recycled aggregate concrete using Artificial Neural Network, Adaptive Neuro-Fuzzy

- Inference System and Multiple Linear Regression. *International Journal of Sustainable Built Environment*, 5(2), 355–369.
<https://doi.org/10.1016/j.ijse.2016.09.003>
- Lange, D. A. (1994). Long-Term Strength Development of Concretes. *Journal of Materials in Civil Engineering*, 6(1), 78–87. [https://doi.org/10.1061/\(ASCE\)0899-1561\(1994\)6:1\(78\)](https://doi.org/10.1061/(ASCE)0899-1561(1994)6:1(78))
- Larrañaga, P. (2010). *Tema 8. Redes Neuronales* (pp. 1–19).
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
<https://doi.org/10.1038/nature14539>
- Liu, K., Zou, C., Zhang, X., & Yan, J. (2021). Innovative prediction models for the frost durability of recycled aggregate concrete using soft computing methods. *Journal of Building Engineering*, 34, 101822. <https://doi.org/10.1016/j.job.2020.101822>
- Llopis Castelló, D. (2008). *Metodología de la investigación*.
- Manzoor, B., Othman, I., Durdyev, S., Ismail, S., & Wahab, M. H. (2021). Influence of artificial intelligence in civil engineering toward sustainable development—a systematic literature review. *Applied System Innovation*, 4(3), 1–17.
<https://doi.org/10.3390/asi4030052>
- Mendoza, J. G., Quispe, M. B., & Muñoz, S. P. (2022). CIVIL ENGINEERING A review on the role of artificial intelligence in the construction industry Una revisión sobre el rol de la inteligencia artificial en la industria de la construcción. *Ingeniería y Competitividad*, 24(2). <https://doi.org/10.25100/iyv.v24i2.11727>
- Mims, C. (2020). *Huang's Law Is the New Moore's Law, and Explains Why Nvidia Wants Arm*. The Wall Street Journal. https://www.wsj.com/articles/huangs-law-is-the-new-moores-law-and-explains-why-nvidia-wants-arm-11600488001#comments_sector
- Mohit, & Lallotra, B. (2021). Approach of artificial intelligence for analysing properties of concrete. *Materials Today: Proceedings*, 48, 1713–1717.
<https://doi.org/10.1016/j.matpr.2021.10.028>
- Orellana López, D., & Sánchez Gómez, M. (2006). Técnicas de recolección de datos en entornos virtuales más usadas en la investigación cualitativa. *Revista de investigación educativa, RIE*, 24(1), 205–222.

- Ponce Cruz, P. (2011). Inteligencia Artificial con aplicaciones a la ingeniería. En A. Herrera (Ed.), *Alfaomega, México* (Primera). Alfaomega.
<http://www.alfaomega.com.mx>
- Rajeshwari, R., & Mandal, S. (2019). Prediction of compressive strength of high-volume fly ash concrete using artificial neural network. *Lecture Notes in Civil Engineering*, 25, 471–483. https://doi.org/10.1007/978-981-13-3317-0_42
- Ramírez, J. (2018). *¿Qué son las Variables Dependiente e Independiente? (Ejemplos)*. lifeder. <https://www.lifeder.com/variables-dependiente-independiente/>
- Reding Bernal, A., Zamora Macorra, M., & López Alvarenga, J. C. (2011). ¿Cómo y cuándo realizar un análisis de regresión lineal simple? Aplicación e interpretación. *Dermatología Revista Mexicana*, 55(6), 395–402.
- Rivva Lopez, E. (1992). *Diseño de Mezclas* (1a ed.).
- Salimbahrami, S. R., & Shakeri, R. (2021). Experimental investigation and comparative machine-learning prediction of compressive strength of recycled aggregate concrete. *Soft Computing*, 25(2), 919–932. <https://doi.org/10.1007/s00500-021-05571-1>
- scikit-learn.org. (2022). 3.1. Cross-validation: evaluating estimator performance — *scikit-learn 1.2.2 documentation*. https://scikit-learn.org/stable/modules/cross_validation.html
- Serrano, F., & Pérez, D. (2010). Análisis de sensibilidad para estimar el módulo de elasticidad estático del concreto. *Concreto y cemento. Investigación y desarrollo*, 2, 17–30. http://www.scielo.org.mx/scielo.php?pid=S2007-30112010000100002&script=sci_arttext
- Setién, J., Carrascal, I. A., Figueroa, J. F., & Polanco, J. A. (2003). Application of an artificial neural network to ready-mixed concretes mix design. *Materiales de Construcción*, 53(270), 5–19. <https://doi.org/10.3989/mc.2003.v53.i270.270>
- Siraj, N. B., Fayek, A. R., & Tsehayae, A. A. (2016). Development and Optimization of Artificial Intelligence-Based Concrete Compressive Strength Predictive Models. *International Journal of Structural and Civil Engineering Research*, July 2018, 156–167. <https://doi.org/10.18178/ijscer.5.3.156-167>

- Song, Y., Wang, X., Li, H., He, Y., Zhang, Z., & Huang, J. (2022). Mixture Optimization of Cementitious Materials Using Machine Learning and Metaheuristic Algorithms: State of the Art and Future Prospects. *Materials*, 15(21), 7830.
<https://doi.org/10.3390/ma15217830>
- Valderrama-Purizaca, F. J., Chávez-Barturen, D. A., Muñoz-Pérez, S. P., Tuesta-Monteza, V., Mejía-Cabrera, H. I., Valderrama-Purizaca, F. J., Chávez-Barturen, D. A., Muñoz-Pérez, S. P., Tuesta-Monteza, V., & Mejía-Cabrera, H. I. (2021). Importancia de las redes neuronales artificiales en la ingeniería civil: Una revisión sistemática de la literatura. *Iteckne*, 18(1), 71–83.
http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S1692-17982021000100071&lng=en&nrm=iso&tlng=es%0Ahttp://www.scielo.org.co/scielo.php?script=sci_abstract&pid=S1692-17982021000100071&lng=en&nrm=iso&tlng=es
- Villayanbre Llamazares, M. (2002). Aproximación al tratamiento del lenguaje desde la perspectiva de la inteligencia artificial (IA). *Estudios Humanísticos. Filología*, 24, 199–228.
- Zhang, F., Chan, A. P. C., Darko, A., Chen, Z., & Li, D. (2022). Integrated applications of building information modeling and artificial intelligence techniques in the AEC/FM industry. *Automation in Construction*, 139(April), 104289.
<https://doi.org/10.1016/j.autcon.2022.104289>
- Zhang, Z., Cui, P., & Zhu, W. (2022). Deep Learning on Graphs: A Survey. *IEEE Transactions on Knowledge and Data Engineering*, 34(1), 249–270.
<https://doi.org/10.1109/TKDE.2020.2981333>