

Les méthodes issues de l'intelligence artificielle au service de l'ingénieur : Applications aux matériaux de construction

Rachid Zentar^{1,2}

¹ *IMT Nord Europe, Institut Mines Télécom, Center of Materials and Processes, Lille, France*

² *Univ. Lille, Institut Mines-Télécom, Univ. Artois, Junia, ULR - LGCgE – Laboratoire de Génie Civil et géo-Environnement, F-59000 Lille, France*

Corresponding author: Rachid ZENTAR (e-mail: rachid.zentar@imt-nord-europe.fr)

RESUME Les méthodes issues de l'intelligence artificielle connaissent un essor exponentiel dans la résolution de problèmes d'ingénierie. Dans l'histoire de la science, l'usage de ces méthodes reste relativement récent pour en tirer toutes les conclusions. Néanmoins sur des cas pratiques, ces méthodes montrent un intérêt croissant pour : la facilité d'utilisation, la capacité d'adaptation en prenant en compte les connaissances récentes, la capacité de résolution des problèmes complexes pour lesquelles une modélisation rigoureuse avec des modèles déterministes est très compliquée à réaliser. Dans cet article, l'objectif principal est de dresser une revue des méthodes issues de l'intelligence artificielle utilisées dans le domaine de l'ingénierie. Les forces de ces méthodes seront illustrées sur quelques cas pratiques en lien avec le domaine de formulation des matériaux de construction. L'article se terminera en proposant quelques pistes de développement.

Mots-clefs Intelligence artificielle, apprentissage automatique, réseaux neuronaux, méthode hybride, formulation béton

I. INTRODUCTION

Le secteur de la construction, qui a participé largement aux développements économique et social pendant des décennies se trouve actuellement face à des difficultés majeures parmi lesquelles : les impacts environnementaux engendrés sur toute la chaîne de valeurs (de l'exploitation de la ressource pour faire des matériaux à la déconstruction de l'ouvrage en fin de vie mais également en phase de construction et d'exploitation de l'ouvrage), combinés à un marché très concurrentiel où la compétitivité est conditionnée par une utilisation optimale des ressources en présence (ressources naturelles non renouvelable et renouvelable, matériaux, matériel, ressources humaines, ...) (Buyle et al., 2013 ; Ofori, 1990 ; Spence & Mulligan, 1995).

L'essor des méthodes numériques au début de la deuxième guerre mondiale, comme la méthode des éléments finis ou la méthode des différences finies, développées à l'origine dans le

secteur de l'aéronautique ont permis dans le secteur de la construction de mieux appréhender le comportement des matériaux et, de même, le dimensionnement de structures de plus en plus complexes (Hrennikoff, 1941 ; Courant, 1943 ; Zienkiewicz et al., 2013). Ces méthodes numériques permettent à partir d'une modélisation géométrique de la structure, le choix d'une loi de comportement pour le matériau utilisé et la définition de conditions aux limites et de chargements, de calculer en certains points de la structure la solution approchée du problème.

Dans ce type d'approche, le résultat est très conditionné par plusieurs éléments : la fidélité ou la complexité de la représentation géométrique adoptée, la fidélité ou la pertinence de la loi de comportement adoptée pour reproduire le comportement du matériau et les méthodes de résolution mises en œuvre.

De nos jours, pour répondre à l'urgence climatique en adoptant les concepts du développement durable les solutions préconisées pour pallier aux manques de ressources naturelles dans le secteur de la construction se diversifient (Ginga et al., 2020 ; Kabirifar et al., 2020 ; Richardson, 2013). Avec cette diversification, il apparaît très difficile de développer toute la connaissance à l'image de ce qui a été fait sur les matériaux standardisés menés sur plusieurs décennies. De plus, dans les nouvelles études, des contraintes supplémentaires sont à intégrer dans le processus de développement de solutions telles que le coût, l'impact environnemental, voire même spécifiquement l'impact CO2 (Xing et al., 2022 ; Balaquera et al., 2018 ; Lopez Ruiz et al., 2020),

Les méthodes de résolution, de problèmes complexes, issues de l'intelligence artificielle ont connu ces deux dernière décennies un développement exponentiel (Das et al., 2015 ; Sha et al., 2020 ; Khanagar et al., 2021). L'usage de ces méthodes se diversifie et va de la reconnaissance faciale, à la conduite de voiture en passant par le décryptage de comportements humains, voire la création d'œuvres artistiques ou d'ouvrages (Poola, 2017 ; Xu et al., 2005 ; Farzaneh et al. 2021).

II. L'INTELLIGENCE ARTIFICIELLE POUR LA RESOLUTION DE PROBLEMES D'INGENIERIE

Avant d'aller plus loin sur l'utilisation des méthodes issues de l'intelligence artificielle dans le domaine de l'ingénierie et plus spécifiquement de la construction, il apparaît important de rappeler quelques concepts et de dresser un bref historique de l'avènement de ces méthodes et/ou de ces concepts.

La publication en 1950 par Alain Turing de l'article scientifique intitulé « computing Machinery and Intelligence » est considérée comme la date de naissance d'une réflexion autour de la capacité d'un ordinateur à remplacer un humain dans un jeu d'imitation (Turing, 2007 ; Copeland, 2004).

Le terme "intelligence artificielle" a été introduit pour la première fois en 1956 par John McCarthy, lors d'une conférence organisée à Dartmouth College aux Etats-Unis (McCarthy et al. 2006 ; Cordeschi, 2007). Cette conférence a été considérée comme le point de départ officiel de la recherche en intelligence artificielle en tant que domaine distinct de l'informatique et des mathématiques. A cette époque, John McCarthy et les autres chercheurs présents à la conférence ont défini l'intelligence artificielle comme "l'étude de la façon dont les ordinateurs peuvent être rendus capables de faire des choses qui, actuellement, nécessitent l'intelligence humaine".

Si l'on se réfère à la définition de l'intelligence artificielle de nos jours, cette dernière n'a que peu évolué sur l'objectif. Sur les moyens, ce domaine a connu un développement exponentiel de technique de traitement de l'information, de l'apprentissage automatique et de la compréhension du raisonnement pour résoudre des problèmes complexes et effectuer des tâches qui nécessitent normalement une intelligence humaine (Wang, 2019).

Il existe plusieurs façons de classer les techniques de résolution de problèmes associées à l'intelligence artificielle (Salehi & Burgueno, 2018 ; Lu et al., 2012). On peut citer les méthodes d'intelligence artificielle dites explicites et des méthodes dites implicites. Dans la classe des méthodes d'intelligences artificielles on retrouve toutes les branches de l'apprentissage automatique. Ce dernier est un sous-domaine de l'IA qui se concentre sur la construction de systèmes qui peuvent apprendre à partir de données et s'améliorer au fil du temps. Il comprend des techniques telles que:

- L'apprentissage supervisé, où un système est entraîné sur des données étiquetées pour prédire des résultats futurs.
- L'apprentissage non supervisé, où un système est entraîné sur des données non étiquetées pour découvrir des structures cachées dans les données.
- L'apprentissage par renforcement, où un système est entraîné à travers une série d'interactions avec son environnement pour maximiser une récompense.

Ces techniques, selon les besoins et les données de chaque projet, s'appuient sur un ensemble de méthodes. Les plus couramment utilisées sont : les réseaux de neurones, les arbres de décision, la régression logistique, les méthodes de forêts aléatoires, les méthodes de clustering, des algorithmes évolutionnaires et bien d'autres méthodes. Ces méthodes sont utilisées selon les besoins et les données de chaque projet, et il peut y avoir des combinaisons de méthodes pour résoudre un problème donné.

Parmi les méthodes qui utilisent les algorithmes évolutionnaires, on peut citer la programmation génétique (PG). Depuis la vulgarisation de la PG dans les années 90 (Koza, 1995), ces outils ne cessent d'évoluer. En effet, les travaux récents, dans la perspective de palier aux lacunes de la PG classique, ont porté sur la combinaison de la PG standard avec d'autres algorithmes. Nous citons à ce titre : les travaux de (Folino et al., 2000) combinant la PG avec les recuits simulés, l'intégration de la PG avec les Algorithmes Génétiques (Brezocnik & Kovacic, 2003), le couplage de la PG avec la méthode des moindres carrés (Madar et al., 2005), les réseaux de neurones artificiels avec la PG (Ravisankar et al., 2010) et la dernière version de la PG proposée par Gandomi (Gandomi & Alavi, 2011) qui est la Multi-Gène Genetic Programming (MGGP) appelée aussi Multi Stage Genetic Programming (MSGP).

III. APPLICATION DE L'IA POUR OPTIMISER LA FORMULATION D'UN BETON INTEGRANT DES SOUS-PRODUITS INDUSTRIELS

Pour le présent cas d'étude, qui porte sur la formulation des BHP, une base de données de la littérature scientifique est utilisée (Lim et al., 2004). Cette base servira d'environnement d'apprentissage dans la modélisation de la résistance mécanique et l'affaissement de ce BHP par la MGGP. La base de données intègre 104 enregistrements, de bétons de résistance mécanique à 28 jours de 40 à 80 MPa et un affaissement de 120 à 260 mm. Une étude préalable a permis d'orienter le choix des inputs sur 6 paramètres d'entrée à savoir : E/L : Rapport eau/liant (%), E :

Dosage en eau (kg/m³), S/G: Rapport massique des agrégats fins (%), CV: Cendres volantes(%), AE : Agent entraîneur d'air (kg/m³), SP : Super Plastifiant (kg/m³).

La méthode adoptée dans cette application est une méthode hybride combinant les AG comme algorithmes d'optimisation multi-objectifs combinés avec la MGGP qui permet de fournir par apprentissage automatique les modèles prédictifs qui représentent les fonctions d'évaluation pour les AG (Sadok et al., 2016). La Figure 1 illustre la démarche globale explicitée ci-dessus.

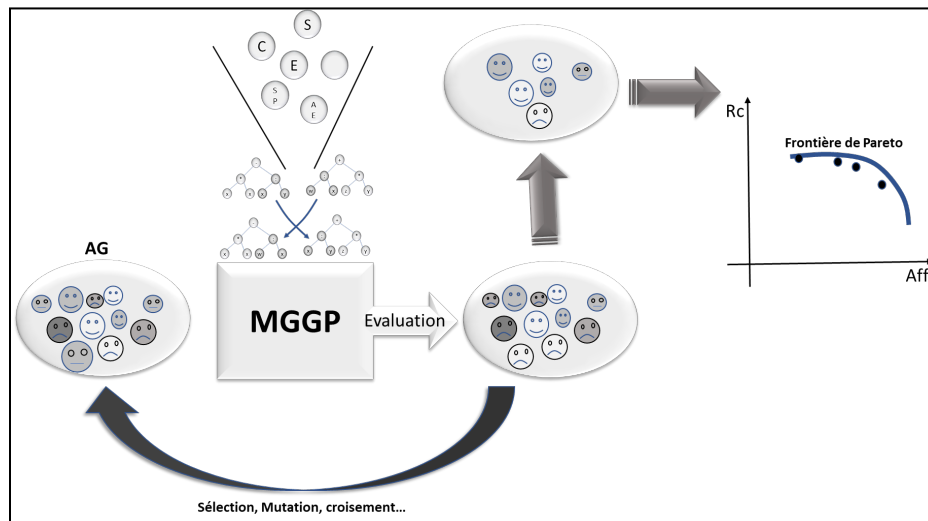


Figure 1. La méthode de formulation des bétons par Algorithmes Génétiques et Programmation Génétique Multi Gène (MGGP).

Il ressort des résultats, montrés en Figure 2, que la prédiction des modèles obtenus par la MGGP est très satisfaisante. Le modèle présente une corrélation avec les résultats expérimentaux $R=0.97$, une erreur moyenne $MAE=1.81$ MPa et un $RMSE$ de 2.20 MPa, ce qui est d'emblée satisfaisant pour un problème similaire. Sur le plan expérimental, la norme en vigueur, relative à la résistance en compression des bétons, admet une erreur type à 4MPa.

Pour l'évaluation des affaissements, le coefficient de corrélation est nettement moins élevé $R=0.55$ (Figure 3). Néanmoins, l'erreur moyenne $MAE=22$ mm et un $RMSE$ de 25.5 mm restent beaucoup plus contenu pour ce type de problème.

Afin de valider la démarche globale telle que proposée sur la Figure 1, on s'est proposé de réaliser un béton qui puisse satisfaire au cahier des charges explicité sur le Tableau 1. Le processus d'optimisation a permis de converger vers un ensemble de solutions (avec des critères et des caractéristiques différents) répondant au cahier des charges (Figure 4).

De ces potentielles solutions, 3 formulations ont été sélectionnées et réalisées au laboratoire. Il apparaît des résultats obtenus et mesurés en laboratoire une bonne correspondance avec les résultats prédits par le modèle (Tableau 2). Cela est vérifié tant pour la résistance à la compression que l'affaissement (écart relatif de l'ordre de 10% ce qui est relativement faible pour de telles études).

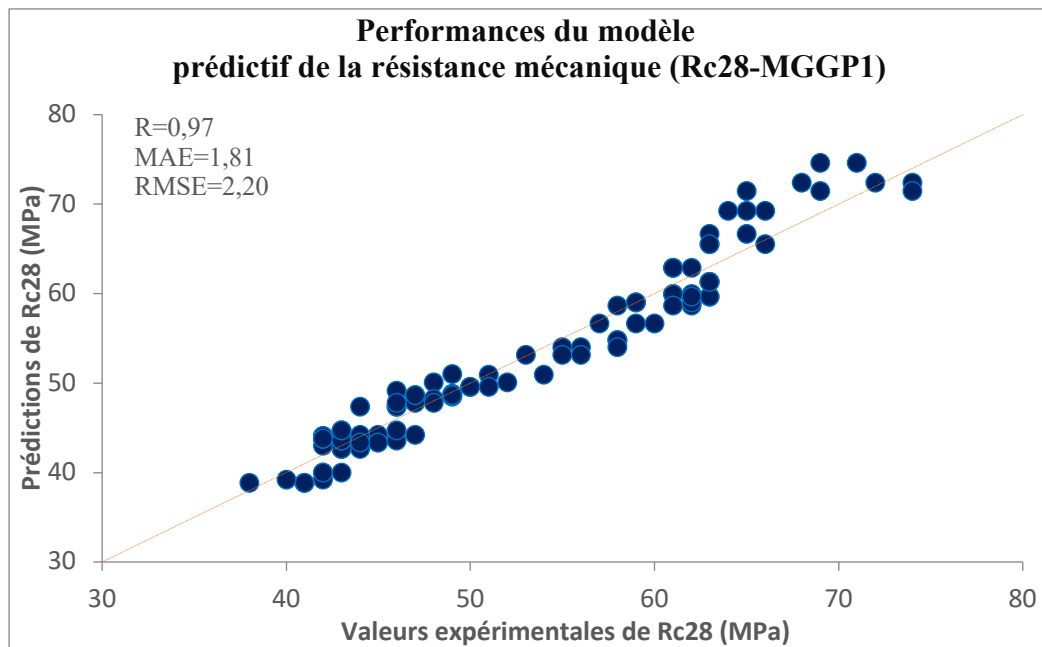


Figure 2. Prédications de Rc 28 avec le modèle issu de la MGGP..

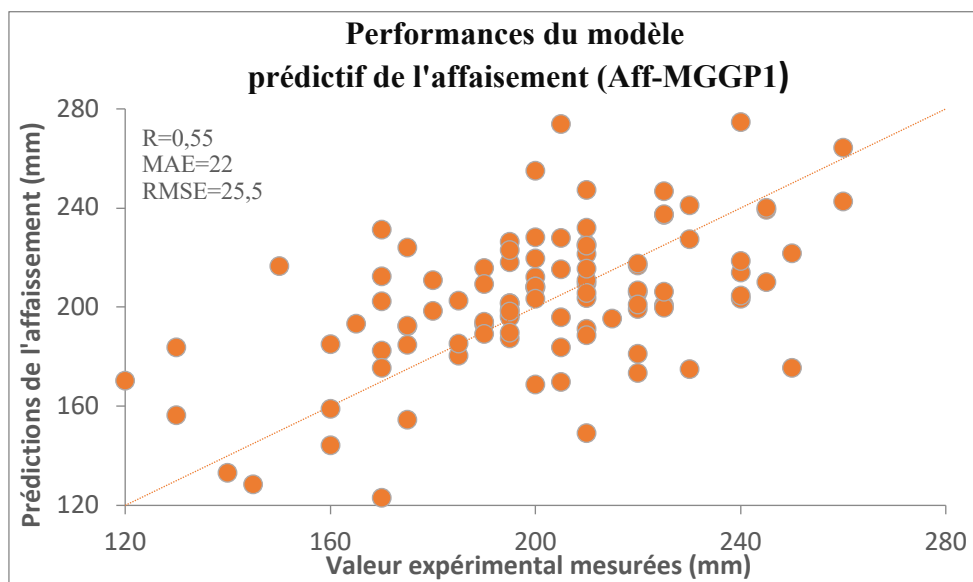


Figure 3. Prédications de l'affaissement avec le modèle issu de la MGGP.

Tableau 1. Cahier de charge d'un BHP.

Propriétés	Unité	Intervalle des caractéristiques
Résistance Mécanique	MPa	40-55
Affaissement	mm	160-170

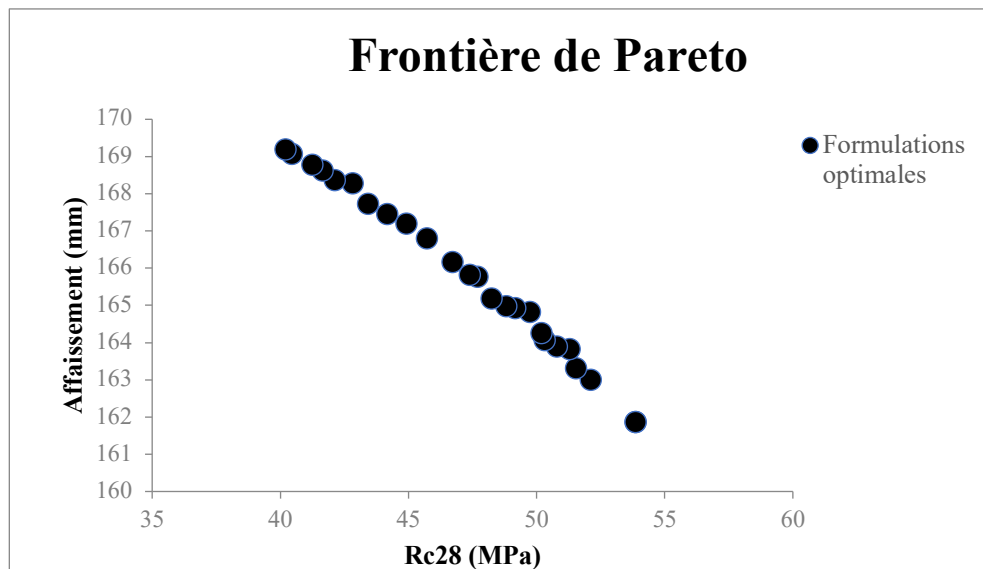


Figure 4. Ensemble de formulations qui répondent potentiellement au cahier des charges du Tableau 1.

Tableau 2: Comparaisons des Résistance mécanique et affaissement obtenus sur les formulations testées en laboratoire avec les prédictions des modèles .

Propriétés	Rc28 (MPa)		Affaissement (mm)		
	Valeurs	Expérimental	Prédictions	Expérimental	Prédictions
Formulation F1		61±3	54	155±20	162
Formulation F4		54±2	50	178±20	165
Formulation F9		45±2	42	175±20	169

IV. APPLICATION DE L'IA POUR PREDIRE LE SEUIL DE CISAILLEMENT DU BETON

Pour le présent cas d'étude, l'objectif principal est de comparer le seuil de cisaillement mesuré sur un béton avec les valeurs prédites en utilisant un modèle semi-empirique et un Réseau de Neurones Artificiel (RNA).

Dans un premier temps, une base de données de 48 formulations a été développée. Pour la phase d'entraînement, les résultats de 34 formulations sont utilisés et les résultats des 14 formulations restantes ont servi pour le test et la validation du modèle (Bala et al., 2019-a ; Bala et al., 2020, Bala et al., 2019-b).

Dans un deuxième temps, un travail a été réalisé pour fixer la structure RNA utilisée et la stratégie d'identification puis de validation du modèle. La structure RNA arrêtée pour cette étude est ainsi composé : d'une couche cachée constituée de 30 neurones, une couche d'output constituée d'un neurone (pour restituer la valeur prédite du seuil de cisaillement). Afin d'analyser

l'impact du nombre de paramètres d'entrées sur la pertinence de la prédiction du RNA, la couche d'entrée est composée soit de deux neurones (deux inputs qui correspondent respectivement à ϕ (la fraction volumique des grains solides) et τ_0 (la contrainte seuil du fluide suspendant entre autre ici la pâte de ciment)), soit de trois neurones (en plus des deux premiers inputs, un paramètre relatif à la compacité maximale de l'empilement ϕ_{max} est ajouté) enfin une couche d'entrée composée de 5 neurones (en addition des trois paramètres utilisés dans le cas n°2, deux autres paramètres qui traduisent le ratio G/S et G1/G2 (rapport de deux classes de gravier) sont ajoutés) (Figure 5).




Figure 5. Structures des RNA utilisées dans cette étude.

La performance de la prédiction après la phase d'entraînement du RNA est reportée sur le Tableau 3 et la Figure 6. Il apparaît de ces résultats, que le modèle à 5 paramètres offre une prédiction nettement meilleure que celle à deux paramètres. L'adjonction des trois paramètres (ϕ_{max} , G/S et G1/G2) améliore nettement la qualité de la prédiction. Lors de la phase d'entraînement, la vitesse de convergence du modèle est aussi améliorée. La prédiction du modèle ARN comparée aux résultats issus d'un modèle développée par une approche purement mécanique qui permet d'identifier le seuil de cisaillement à partir de la mesure de l'affaissement (Saak et al., 2004 ; Murata, 1984) montre également une bonne correspondance des résultats avec la prédiction du RNA.

Tableau 3. Optimisation de la nature et du nombre de données d'entrée pour la prédiction du seuil de cisaillement par les RNA

Données d'entrée	Données d'entraînement	Données de test	RMSE entraînement (Pa)	RMSE test (Pa)
$\phi + \tau_0$	34 paires (sélectionnées)	14 paires	270	415
$\phi + \tau_0 + \phi_{max}$			172	345
$\phi + \tau_0 + \phi_{max} + G/S + G_2/G_1$			127	234




Figure 6. Seuils de cisaillement déterminés par Saak et al. vs. modélisés par les RNA en optimisant les données d'entrée : $\phi + \tau_0 + \phi_{max}$

V. CONCLUSION

L'avènement dans le domaine de la construction en général et des matériaux de construction en particulier de nouveaux composants, de nouveaux constituants, de nouvelles technologies et la prise en compte de nouvelles contraintes (environnementales, réglementaires, disponibilités de la ressource, ...) nécessite de s'adapter aux contextes rapidement et mettre à profit les évolutions majeures entreprises dans d'autres secteurs d'activités.

Pour répondre aux challenges présents et surtout à venir dans le domaine du développement de matériaux de construction : les méthodes issues de l'intelligence artificielle peuvent devenir un allié important de l'ingénieur dans les années à venir. Cette aide au développement d'outils numériques ne peut se passer, comme par le passé, de l'expertise et de la connaissance des matériaux pour les enrichir et les rendre adaptable.

Le succès de ces méthodes est aussi largement basé sur l'apprentissage à partir de l'expérience. A ce stade, l'expertise acquise par les spécialistes est un gage de réussite de ces approches.

Dans la présente étude, deux exemples d'applications sont présentés. Le premier a permis de montrer la capacité d'approches basées sur l'IA à aider à la formulation de béton respectant un cahier des charges spécifique. Ces méthodes ont été adaptées à l'utilisation de ressources non standard pour formuler ces bétons. La deuxième application a permis de montrer la capacité d'outils issus de l'IA à prédire des propriétés du béton frais à savoir le seuil de cisaillement (propriété capitale pour assurer en général une bonne mise en œuvre) à partir de propriétés physiques facilement mesurables au laboratoire.

REFERENCES

Bala, M., Zentar, R. & Boustingorry, P., 2019-a. Modèles prédictifs de l'affaissement du béton : Cas de granulats concassés et roulés. *AJCE*, vol 37, No 1, Special Issue - RUGC 2019 Sophia Antipolis.

Bala, M., Zentar, R. & Boustingorry, P., 2020. Parameter determination of the Compressible Packing Model (CPM) for concrete application. *Powder Technology* 367, 56–66. <https://doi.org/10.1016/j.powtec.2019.11.085>.

Bala, M., Zentar, R. & Boustingorry, P., 2019-b. Détermination des contraintes seuil des pâtes de ciment en vue d'une optimisation de la rhéologie des bétons. 9e Edition des Journées scientifiques du Regroupement Francophone pour la Recherche et la Formation sur le Béton (RF)2B. SIAME.

Balaguera, A., Carvajal, G. I., Albertí, J. & Fullana-i-Palmer, P., 2018. Life cycle assessment of road construction alternative materials: A literature review. *Resources, Conservation and Recycling* 132, 37–48.

Brezocnik, M., Kovacic, M., 2003. Integrated Genetic Programming and Genetic Algorithm Approach to Predict Surface Roughness. *Materials and Manufacturing Processes* 18, 475–491. doi:10.1081/AMP-12002202

Buyle, M., Braet, J. & Audenaert, A., 2013. Life cycle assessment in the construction sector: A review. *Renewable and Sustainable Energy Reviews* 26, 379–388. <http://dx.doi.org/10.1016/j.rser.2013.05.001>.

Copeland B. J., 2005. *The essential Turing: seminal writings in computing, logic, philosophy, artificial intelligence, and artificial life plus the secrets of Enigma*. Clarendon Press, ISBN 0–19–825079–7.

Cordeschi, R., 2007. AI TURNS FIFTY: REVISITING ITS ORIGINS. *Applied Artificial Intelligence* 21, 259–279.

Courant, R., 1943. Variational methods for the solution of problems of equilibrium and vibrations. *Bulletin of the American Mathematical Society*. 49: 1–23. doi:10.1090/s0002-9904-1943-07818-4.

Das, S., Dey, A., Pal, A. & Roy, N., 2015. Applications of Artificial Intelligence in Machine Learning: Review and Prospect. *IJCA* 115, 31–41.

Farzaneh, H., Malehmirchegini, L., Bejan, A., Afolabi, T., Mulumba, A., and Dak, P. P., 2021. Artificial Intelligence Evolution in Smart Buildings for Energy Efficiency. *Applied Sciences* 11, 763. doi.org/10.3390/app11020763.

Folino, G., Pizzuti, C. & Spezzano, G., 2000. Genetic Programming and Simulated Annealing: A Hybrid Method to Evolve Decision Trees. in *Genetic Programming* (eds. Poli, R. et al.) vol. 1802 294–303 (Springer Berlin Heidelberg).

Gandomi, A. H. & Alavi, A. H., 2011. Multi-stage genetic programming: A new strategy to nonlinear system modeling. *Information Sciences* 181, 5227–5239.

Ginga C. P., Ongpeng J. M. C. and Daly M. K. M., 2020. Circular Economy on Construction and Demolition Waste: A Literature Review on Material Recovery and Production. doi.org/10.3390/ma13132970.

Hrennikoff, A., 1941. Solution of problems of elasticity by the framework method". *Journal of Applied Mechanics*. 8 (4): 169–175. doi:10.1115/1.4009129

Kabirifar, K., Mojtahedi, M., Wang, C. & Tam, V. W. Y., 2020. Construction and demolition waste management contributing factors coupled with reduce, reuse, and recycle strategies for effective waste management: A review. *Journal of Cleaner Production* doi.org/10.1016/j.jclepro.2020.121265.

Khanagar, S. B., Al-ehaideb, A., Maganur, P. C., Vishwanathalah, S., Patil, S., Baeshen, H. A., Sarode, S. C., and Bhandi, S., 2021. Developments, application, and performance of artificial intelligence in dentistry – A systematic review. *Journal of Dental Sciences* 16, 508–522.

Koza, J. R., 1995. Survey of genetic algorithms and genetic programming. in *Proceedings of WESCON'95* 589 (IEEE, 1995). doi:10.1109/WESCON.1995.485447.

Lim, C.-H., Yoon, Y.-S. & Kim, J.-H., 2004. Genetic algorithm in mix proportioning of high-performance concrete. *Cement and Concrete Research* 34, 409–420.

López Ruiz, L. A., Roca Ramón, X. & Gassó Domingo, S., 2020. The circular economy in the construction and demolition waste sector – A review and an integrative model approach. *Journal of Cleaner Production* 248, 119238.

Lu, P., Chen, S. & Zheng, Y., 2012. Artificial Intelligence in Civil Engineering. *Mathematical Problems in Engineering* 2012, 1–22.

Madár, J., Abonyi, J. & Szeifert, F., 2005. Genetic Programming for the Identification of Nonlinear Input–Output Models. *Ind. Eng. Chem. Res.* 44, 3178–3186.

McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E., 2006. A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI magazine*, 27(4), 12- https://doi.org/10.1609/aimag.v27i4.1904.

Murata, J., 1984. Flow and deformation of fresh concrete. *Matériaux et Constructions*. Vol. 17, N° 98. 117–129.

Ofori, G., 1990. *The Construction Industry: Aspects of Its Economics and Management* Singapore University Press. ISBN 9971-69-148-5.

Poola, I., 2017. *How Artificial Intelligence in Impacting Real life Everyday*. (2017).

Ravisankar, P., Ravi, V. & Bose, I., 2010. Failure prediction of dotcom companies using neural network–genetic programming hybrids. *Information Sciences* 180, 1257–1267.

Richardson, A., 2013. Reuse of Materials and Byproducts in Construction: Waste Minimization and Recycling. Springer London. doi/10.1007/978-1-4471-5376-4.

Saak, A. W., Jennings, H. M. & Shah, S. P., 2004. A generalized approach for the determination of yield stress by slump and slump flow. *Cement and Concrete Research* 34, 363–371. doi:10.1016/j.cemconres.2003.08.005.

Sadok, A., Zentar, R. & Abriak, N.-E., 2016. Genetic programming for granular compactness modelling. *European Journal of Environmental and Civil Engineering* 20, 1249–1261.

Salehi, H. & Burgueño, R., 2018. Emerging artificial intelligence methods in structural engineering. *Engineering Structures* 171, 170–189.

Sha, W., Guo, Y., Yuan, Q., Tang, S., Zhang, X., Lu, S., Guo, X., Cao, Y-C., and Cheng, S., 2020. Artificial Intelligence to Power the Future of Materials Science and Engineering. *Advanced Intelligent Systems* 2, 1900143.

Spence, R. & Mulligan, H., 1995. Sustainable development and the construction industry. *Habitat International* 19, 279–292.

Turing, A. M., 2007. *Computing Machinery and Intelligence*. doi: 10.1007/978-1-4020-6710-5_3.

Wang, P., 2019. On Defining Artificial Intelligence. *Journal of Artificial General Intelligence* 10, 1–37.

Xing, W., Tam, V. W., Le, K. N., Hao, J. L. & Wang, J., 2022. Life cycle assessment of recycled aggregate concrete on its environmental impacts: A critical review. *Construction and Building Materials* 317, 125950.

Xu, S.; Lau F.C.M.; Cheung W.K.; Pan Y.; 2005. Automatic generation of artistic chinese calligraphy | *IEEE Journals & Magazine*. VOL. 20, Issue 3. 32-39. doi: 10.1109/MIS.2005.41 |

Zienkiewicz O. C.; Taylor R. L.; Zhu J.Z., 2013. *The Finite Element Method: Its Basis and Fundamentals*. Butterworth-Heinemann. ISBN 978-0-08-095135-5.