

Optimisation de la composition du béton à base de granulats recyclés pour une résistance à la compression maximale à l'aide de la méthode des plans d'expériences et d'un modèle d'apprentissage automatique

Paterne CIRHUZA BADESIRE^{1,2}, Noëlie DI CESARE¹, Xuan Hong VU¹, Chérif BISHWEKA²

¹ Université de Lyon, Université Claude Bernard Lyon 1, EA-7427, Laboratoire des Matériaux pour la Construction (LMC2), F-69622 Villeurbanne, France; paterne.cirhuza-badesire@etu.univ-lyon1.fr; noelie.di-cesare@univ-lyon1.fr; xuan-hong.vu@univ-lyon1.fr

² Université Libre des Pays des Grands Lacs (ULPGL/GOMA), 2 Avenue du Lac, BP 368 GOMA, Nord-Kivu, DR Congo; cbishweka@ulpgl.net

RESUME

Le béton est l'un des matériaux les plus utilisés dans le secteur de la construction, l'optimisation de sa composition pose des défis particuliers, notamment à cause des interactions complexes entre ses différents composants. Les méthodes conventionnelles, bien qu'utilisées, sont souvent coûteuses en termes d'expérimentation et peinent à appréhender la complexité des interactions entre les constituants. Cette recherche propose une approche novatrice combinant la méthode des plans d'expériences et l'apprentissage automatique pour l'optimisation des formulations de béton à base de granulats recyclés. Un modèle de régression CatBoost, entraîné sur un ensemble de données de 594 compositions de mélanges, a été utilisé pour prédire les réponses du plan d'expériences. Deux études de cas ont été considérées afin de démontrer l'efficacité de cette méthode. Les résultats obtenus indiquent que l'approche proposée permet de concevoir les mélanges de béton de manière précise et fiable, tout en réduisant le nombre d'expérimentations nécessaires en vue d'identifier la configuration optimale.

Mots-clés Béton à base de granulats recyclés, Plans d'expériences, Apprentissage automatique, Résistance à la compression, Béton recyclé.

I. INTRODUCTION

Le béton est l'un des matériaux les plus utilisés dans le secteur de la construction, en raison de sa durabilité, de sa disponibilité et de sa polyvalence (P. Kumar Mehta, 2006). On estime que la production mondiale de béton atteint environ 30 milliards de tonnes par an (Paulo J. Monteiro et al., 2017), ce qui pose des défis significatifs en matière de durabilité en raison de la consommation de ressources et de l'impact environnemental associés. La demande en matières premières, telles

que les granulats naturels et le ciment, entraîne une déplétion substantielle des ressources naturelles et contribue à des préoccupations environnementales, notamment concernant les émissions de gaz à effet de serre et la production de déchets de construction (Yap et al., 2018).

Le béton de granulats recyclés (BGR) est apparu comme une solution prometteuse à ces défis, offrant une approche durable pour réutiliser les déchets issus de la construction et de la démolition (de Larrard F. et Colina H. (Dir.), 2018). Recycler le béton usagé pour produire des granulats destinés à de nouvelles formulations de béton permet de réduire la consommation de granulats naturels (Malhotra, 1976). Malgré ses avantages environnementaux, l'optimisation de la composition des mélanges de BGR pour atteindre des performances optimales demeure une tâche complexe, principalement en raison de la nature et des interactions complexes entre les différents composants du mélange (Ben Chaabene *et al.*, 2020).

L'approche traditionnelle utilisée pour concevoir les formulations de béton repose largement sur des méthodes empiriques et des expérimentations par essais-erreurs pour atteindre les propriétés cibles (François de Larrard, 1999). Bien que ces méthodes puissent être efficaces, elles sont souvent chronophages, coûteuses et peuvent ne pas capturer adéquatement les relations complexes entre les composants du BGR, en particulier en raison de la variabilité de la qualité des granulats recyclés, qui ajoute une couche supplémentaire de complexité au processus de conception des mélanges. L'utilisation des techniques de Plans d'Expériences (DoE, *Design of Experiments*) a émergé comme une approche systématique pour optimiser la composition des mélanges à l'aide d'un plan expérimental structuré, permettant une exploration plus efficace des facteurs influençant les propriétés du BGR. Bien que le DoE fournisse une approche structurée pour optimiser les mélanges, il nécessite encore la réalisation de plusieurs expériences pour identifier la composition optimale.

Compte tenu des limites des approches traditionnelles pour traiter les relations hautement non linéaires et multidimensionnelles caractéristiques des propriétés du béton, les méthodes basées sur les données, comme l'Apprentissage Automatique (AA) (Ben Chaabene et al., 2020; Salehi & Burgueño, 2018), ont gagné en popularité dans le domaine de la prédiction des propriétés de béton (Gao et al., 2023; Han et al., 2023; Huang et al., 2023; Pal et al., 2023; Zhang et al., 2023). Les techniques d'AA offrent la capacité à analyser de grands ensembles de données, mais aussi à détecter des schémas complexes et à faire des prédictions précises. En appliquant des algorithmes d'AA à la prédiction des propriétés du béton, il est possible d'améliorer la précision de l'estimation de la résistance à la compression et de réduire le besoin d'un travail expérimental étendu (Mai et al., 2023b). Ces dernières années, divers modèles d'AA, notamment les réseaux de neurones artificiels (ANN), les arbres de décision, les machines à vecteurs de support et les méthodes d'ensemble, ont été utilisés pour prédire la résistance à la compression du béton conventionnel et des BGR avec des résultats prometteurs (Khan and Abbas, 2023; Quan Tran et al., 2022; Wu and Zhou, 2022; Zhang et al., 2023).

Parmi les techniques d'AA, les modèles d'apprentissage par ensemble, tels que le *Gradient Boosting*, le *Light Gradient Boosting Machine* et l'*Extreme Gradient Boosting* (CatBoost), ont gagné en popularité grâce à leur grande précision prédictive et à leur capacité à gérer les relations non linéaires (Mai et al., 2023b, 2023a). Lorsqu'ils sont combinés avec des techniques de DoE, les modèles AA peuvent être utilisés pour prédire systématiquement les propriétés du BGR pour chaque mélange dans le cadre du DoE et explorer les effets de divers facteurs sur les performances du BGR, optimisant ainsi

la conception du mélange avec un nombre réduit d'expériences, en se concentrant uniquement sur les propriétés optimales identifiées correspondant à la composition optimale du mélange.

C'est dans ce contexte que s'inclut cet article, en présentant cette approche novatrice qui intègre le DoE et l'AA avec le modèle de régression CatBoost (Dorogush et al., 2017; Prokhorenkova et al., 2017) pour optimiser la conception des mélanges de BGR. Pour illustrer l'application pratique de la méthodologie proposée, deux études de cas ont été considérées pour évaluer l'efficacité de cette approche dans l'optimisation des mélanges de BGR.

II. METHODOLOGIE

Cette étude propose une approche pour optimiser la composition des mélanges de béton de granulats recyclés (BGR) afin d'obtenir une résistance à la compression optimale. L'approche combine les techniques de Plans d'Expériences (DoE) et d'AA, en utilisant un modèle CatBoost. La méthodologie globale est illustrée à la Figure 1. **Elle se compose de deux volets principaux : la mise en œuvre du modèle CatBoost et la prédiction des réponses du DoE, qui, dans cette étude, correspond à la prédiction de la résistance à la compression pour chaque composition de mélange générée dans le DoE.**

La mise en œuvre du modèle comprend plusieurs étapes, notamment la collecte des données, leur prétraitement, le développement du modèle, l'optimisation des hyperparamètres et la validation. Une fois le modèle développé, il est utilisé pour prédire la résistance à la compression du BGR pour les différentes compositions générées par le DoE. Après avoir prédit les valeurs de résistance à la compression, la composition optimale du mélange est déterminée en identifiant la configuration qui offre la résistance à la compression prédite la plus élevée. Ce processus peut être réalisé soit en inversant le modèle, soit en sélectionnant l'entrée correspondante dans l'ensemble de données prédit par le DoE.

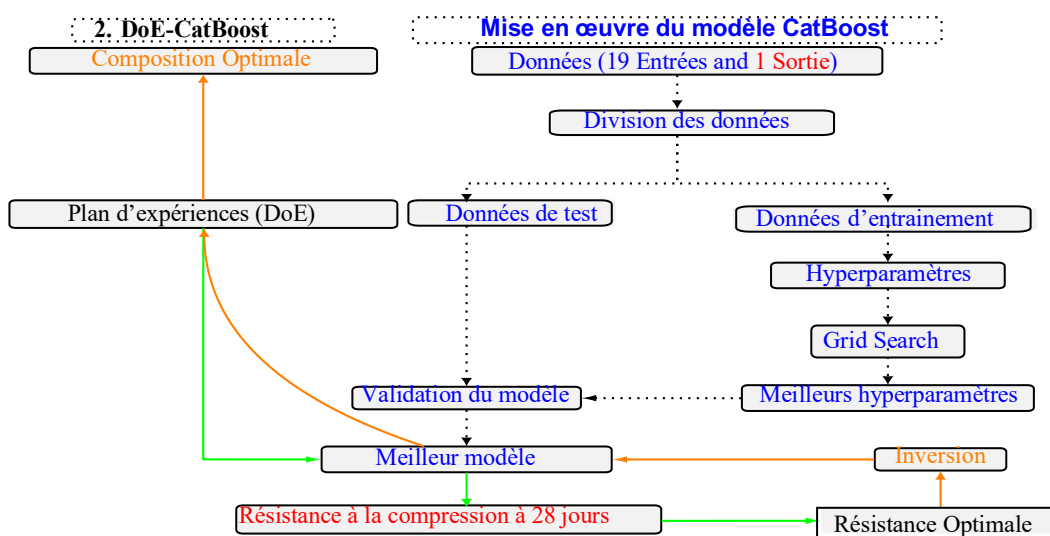


FIGURE 1. Optimisation de la composition avec le DoE - CatBoost

A. Implémentation de CatBoost

Les données utilisées dans cette étude comprennent 594 compositions différentes de mélanges de béton à base de granulats recyclés (BGR), collectées à partir de diverses études de la littérature. Afin de tenir compte de l'effet de la taille des éprouvettes sur la résistance à la compression, des facteurs de conversion (coefficient de de résistance) ont été appliqués pour standardiser les mesures à un cylindre de 160 mm × 320 mm, conformément aux recommandations de recherches antérieures (Chen *et al.*, 2022; Luan *et al.*, 2021). Un paramètre de catégorisation supplémentaire appelé « éprouvette » a été pris en compte pour classer les éprouvettes en cinq catégories : 100 mm × 200 mm (valeur : 0.1), 150 mm × 300 mm (valeur : 0.2), 100 mm cube (valeur : 0.3), 150 mm cube (valeur : 0.4), and 75 mm × 150 mm cylindre (valeur : 0.5). Les statistiques descriptives des ensembles de données d'entraînement et de test sont présentées dans le Tableau 1, qui fournit un aperçu des données utilisées pour le développement du modèle et décrit leurs valeurs moyennes, écarts-types (ET), minima, maxima et quartiles (25e, 50e et 75e percentiles).

Le prétraitement des données a été effectué pour garantir la qualité et la cohérence de l'ensemble de données. Par la suite, les données ont été divisées en ensembles d'entraînement et de test selon un ratio de 80:20. Afin d'évaluer les performances du modèle et de réduire les risques de sur-apprentissage (*overfitting*), une technique de validation croisée *k-fold* (Picard *et al.*, 1984) avec $k = 10$ a été utilisée. Cette méthode a permis d'entraîner le modèle sur plusieurs sous-ensembles de données, renforçant ainsi ses capacités de généralisation à travers différents échantillons.

TABLEAU 1. Résumé des composantes principales

Données d'entrée du modèle ¹	Moyenne	ET	Min	25%	50%	75%	Max
Éprouvette	0.25	0.11	0.1	0.2	0.3	0.3	0.5
Taille GR (mm)	20.49	3.15	12	20	20	20	32
Absorption GR (%)	4.74	1.76	0	3.5	4.65	5.7	12.7
Quantité GR (kg/m ³)	486.19	386.63	0	183.2	471	864.7	1267
GR SSS (kg/m ³)	2422.44	107.34	1946	2340	2400	2500	2661
Absorption SR (%)	10.41	2.81	5.37	10.9	10.9	10.9	13.8
Quantité SR (kg/m ³)	125.98	188.96	0	0	0	204	668
Taille GN (mm)	21.25	3.55	12	20	20	20	32
Absorption GN (%)	1.10	0.73	0	0.7	1.00	1.31	5.4
Quantité GN (kg/m ³)	582.9	426.43	2500	2600	2620	2720	2860
GN SSS (kg/m ³)	2646.93	80.13	0	614	696	794.31	1065
Quantité NFA (kg/m ³)	703.03	139.3	0	20	50	100	100
Taux de remplacement G (%)	47.89	38.03	0	20	50	100	100
Taux de remplacement Sable (%)	34	35.14	0	0	30	50	100
Cendres volantes (kg/m ³)	60.03	61.31	0	0	84	102.5	227.5
Rapport eau-ciment (E/C)	0.51	0.12	0.28	0.43	0.49	0.56	1.3
Teneur en ciment (kg/m ³)	375.61	79.32	147.5	325	380.00	409.75	650
Teneur en adjuvant (%)	0.68	0.69	0	0.00	0.60	1.20	5.2
Résistance à 28 jours (MPa)	44.14	11.8	15.4	36.42	42.9	50.95	80.8

¹ SSS : Saturé à Surface Sèche, SR : Sable Recyclé, SN : Sable Naturel, GN : Gravier Naturel, GR : Gravier Recyclé, G : Gravier.

Données d'entrée du modèle ²	Moyenne	ET	Min	25%	50%	75%	Max
Coefficient de résistance	0.9	0.08	0.79	0.83	0.88	0.97	0.99

Le modèle CatBoost (Hancock and Khoshgoftaar, 2020; Prokhorenkova *et al.*, 2017) a été choisi pour sa robustesse à appréhender les relations non linéaires au sein des données. En tant que technique d'apprentissage par ensemble basée sur le *gradient boosting*, CatBoost est particulièrement adapté pour capturer les dépendances complexes entre les variables d'entrée et la variable cible, qui est ici la résistance à la compression.

Pour optimiser les performances du modèle, un réglage des hyperparamètres a été effectué à l'aide de la méthode *Grid Search* (Liashchynskyi and Liashchynskyi, 2019), qui explore systématiquement différentes combinaisons d'hyperparamètres afin d'identifier la configuration optimale.

Le modèle final a été entraîné à l'aide de l'ensemble d'entraînement avec les hyperparamètres optimisés. Ses performances prédictives ont été évaluées en utilisant quatre métriques statistiques : le coefficient de détermination (R^2), l'erreur quadratique moyenne (RMSE), l'erreur maximale et l'erreur absolue moyenne (MAE). Ces métriques ont permis de mesurer la précision et la fiabilité du modèle pour prédire la résistance à la compression.

L'ensemble de la méthodologie a été implémenté en Python, en utilisant plusieurs bibliothèques pour différentes étapes du processus. Pandas (Nelli, 2015) a été utilisé pour la manipulation des données, Matplotlib (Hunter, 2007) pour la création de visualisations, et Scikit-learn (Pedregosa *et al.*, 2011) pour l'implémentation du modèle.

B. Application des plans d'expériences et de CatBoost

Après l'implémentation du modèle CatBoost, des prédictions ont été générées pour chaque configuration de mélange proposé par le plan d'expériences. L'approche DoE permet une analyse des effets de plusieurs paramètres sur la résistance à la compression. L'objectif était d'identifier la composition optimale du mélange qui maximise la résistance à la compression tout en minimisant le nombre d'expériences nécessaires.

Cet objectif a été atteint en comparant les niveaux optimaux identifiés sur la base des réponses mesurées dans le DoE avec ceux obtenus à partir des valeurs prédites par le modèle CatBoost. Cette comparaison met en évidence le potentiel de l'apprentissage automatique pour guider efficacement le processus d'optimisation, réduisant les efforts expérimentaux en se concentrant sur les configurations les plus prometteuses.

Deux études de cas ont été utilisées pour valider cette approche, démontrant sa capacité à rationaliser l'optimisation de la conception des mélanges de béton. Les données relatives aux compositions des mélanges issues de Huang *et al.* (2024) pour la première étude de cas et de Hammoudi *et al.*, (2019) pour la deuxième étude de cas sont présentées dans les Tableaux 2 et 3, respectivement. Ces tableaux fournissent une vue détaillée du nombre d'expériences, des variables et des valeurs considérées dans chaque étude de cas.

Enfin, la résistance à la compression des mélanges sera prédite numériquement et comparée aux valeurs obtenues expérimentalement afin de valider la pertinence de notre approche.

² SSS : Saturé à Surface Sèche, SR : Sable Recyclé, SN : Sable Naturel, GN : Gravier Naturel, GR : Gravier Recyclé, G : Gravier.

TABLEAU 2. Données pour l'étude de cas 1

Numéro d'expérience	1	2	3	4	5	6	7	8	9
Éprouvette	Cube 100x100x100 mm								
Taille GR (mm)	19	19	19	19	19	19	19	19	19
Absorption GR (%)	5.2	5.2	5.2	5.2	5.2	5.2	5.2	5.2	5.2
Quantité GR (kg/m ³)	753	750	768	971	1014	1038	1231	1285	1255
GR SSS (kg/m ³)	2686	2686	2686	2686	2686	2686	2686	2686	2686
Taille GN (mm)	19	19	19	19	19	19			
Absorption GN (%)	0.5	0.5	0.5	0.5	0.5	0.5	0	0	0
Quantité GN (kg/m ³)	502	500	512	243	254	259			
GN SSS (kg/m ³)	2727	2727	2727	2727	2727	2727			
Quantité NFA (kg/m ³)	706	766	751	744	745	730	723	723	723
Taux de remplacement G (%)	60	60	60	80	80	80	100	100	100
Rapport eau-ciment (E/C)	0.47	0.54	0.6	0.5	0.58	0.64	0.53	0.61	0.68
Teneur en ciment (kg/m ³)	379	327	300	379	327	300	379	327	300
Teneur en adjuvant (%)	1.5	1.49	1.5	1.5	1.49	1.5	1.5	1.49	1.6
Résistance à 28 jours (MPa)	41.67	36.69	32.62	38.96	34.55	28.93	36.21	30.4	27.84
Coefficient de résistance	0.88	0.88	0.88	0.88	0.88	0.88	0.88	0.88	0.88

TABLEAU 3. Données pour l'étude de cas 2

Numéro d'expérience	1	2	3	4	6	7	8	9
Éprouvette	Cube de 150x150x150 mm							
Taille GR (mm)	0	0	25	25	0	0	25	25
Absorption GR (%)	0	0	5.1	5.1	0	0	5.1	5.1
Quantité GR (kg/m ³)	0	0	1061.42	1034.38	0	0	1010.1	975.5
GR SSS (kg/m ³)	0	0	2412	2412	0	0	2412	2412
Taille GN (mm)	25	25	0	0	25	25	0	0
Absorption GN (%)	0.5	0.5	0	0	0.5	0.5	0	0
Quantité GN (kg/m ³)	1193.11	1191.72	0	0	1105.13	1072.27	0	0
GN SSS (kg/m ³)	2630	2630	0	0	2630	2630	0	0
Quantité NFA (kg/m ³)	692.81	675.16	692.81	675.16	659.3	640	659	636.7
Taux de remplacement G (%)	0	0	100	100	0	0	100	100
Rapport eau-ciment (E/C)	0.65	0.71	0.81	0.84	0.49	0.55	0.6	0.64
Teneur en ciment (kg/m ³)	300	300	300	300	400	400	400	400
Résistance à 28 jours (MPa)	30.64	26.45	25.21	23.42	49.41	41.51	37.94	34.6
Coefficient de résistance	0.83	0.83	0.83	0.83	0.83	0.83	0.83	0.83

Numéro d'expérience (suite)	10	11	12	13	14	15	16	17
Éprouvette	Cube de 150x150x150 mm							
Taille GR (mm)	25	25	25	25	25	25	25	25
Absorption GR (%)	5.1	5.1	5.1	5.1	5.1	5.1	5.1	5.1
Quantité GR (kg/m ³)	496.05	518.26	501.73	506.24	506.24	496.05	518.26	501.7
GR SSS (kg/m ³)	2412	2412	2412	2412	2412	2412	2412	2412
Taille GN (mm)	25	25	25	25	25	25	25	25
Absorption GN (%)	0.5	0.5	0.5	0.5	0.5	0.5	0.5	0.5
Quantité GN (kg/m ³)	542.71	572.43	548.94	553.89	553.89	567.03	572.43	542.7
GN SSS (kg/m ³)	2630	2630	2630	2630	2630	2630	2630	2630
Quantité NFA (kg/m ³)	647.54	676.55	657.97	660.86	660.86	683	676.55	647.5
Taux de remplacement G (%)	50	50	50	50	50	50	50	50
Rapport eau-ciment (E/C)	0.57	0.63	0.67	0.65	0.65	0.63	0.57	0.67
Teneur en ciment (kg/m ³)	300	350	350	350	350	350	300	350
Résistance à 28 jours (MPa)	38.71	34.67	30.59	30.86	29.26	26.45	28.7	30.5
Coefficient de résistance	0.83	0.83	0.83	0.83	0.83	0.83	0.83	0.83

III. RÉSULTATS

Cette section présente les résultats de la recherche, en commençant par l'évaluation des performances du modèle (section III.A). La section III.B discute ensuite de l'optimisation de la composition des mélanges à l'aide de l'approche combinée DoE-CatBoost.

A. Évaluation des performances du modèle

Les performances du modèle ont été évaluées à l'aide de quatre métriques. Comme illustré à la Figure 2, la corrélation élevée entre les valeurs prédites et mesurées de la résistance à la compression témoigne de la précision prédictive du modèle. Le Tableau 4 résume davantage les métriques de performance du modèle pour les ensembles de données d'entraînement et de test.




FIGURE 2. Performance du modèle CatBoost : Comparaison entre les valeurs prédites et mesurées

Les résultats montrent que le modèle atteint une précision prédictive élevée pour les ensembles de données d'entraînement et de test, avec un score R^2 de 0,99 pour l'entraînement et de 0,88 pour le test. Cela démontre l'efficacité du modèle à généraliser sur de nouvelles données, comme en témoignent les faibles valeurs d'erreurs présentées dans le Tableau 4.

TABLEAU 4. Métriques de performance pour le meilleur modèle de régression CatBoost

Métrique de performance	Entraînement	Test
Erreur quadratique moyenne (MSE)	1,24	15,62
Coefficient de détermination (Score R^2)	0,99	0,88
Erreur maximale	4,67	18,43
Erreur absolue moyenne en pourcentage (MAPE)	0,02	0,07
Erreur quadratique moyenne (RMSE)	1,11	3,95

B. Optimisation de la composition des mélanges

Cette section illustre l'efficacité de l'utilisation de l'apprentissage automatique pour réduire le nombre d'expériences nécessaires en prédisant les réponses pour chaque configuration dans un DoE. L'objectif est de ne réaliser que l'expérience associée au mélange optimal identifié. Pour ce faire, **les niveaux optimaux identifiés à partir des réponses mesurées du DoE ont été comparés à ceux obtenus à partir des valeurs prédites par le modèle CatBoost.** Cette comparaison met en évidence le potentiel de l'apprentissage automatique pour guider précisément le processus d'optimisation tout en minimisant les efforts expérimentaux.

B.1 Étude de cas 1

Dans la première étude de cas, un DoE comprenant neuf essais a été mis en œuvre, chacun correspondant à une formulation spécifique de béton. Ce DoE, présenté dans le Tableau 5, inclut trois facteurs : A, B et C, correspondant respectivement au taux de remplacement des gravillons, au rapport eau/ciment et au pourcentage de sable. Chacun de ces facteurs est étudié à trois niveaux : 60 %, 80 % et 100 % pour le facteur A ; 0,38, 0,43 et 0,48 pour le rapport eau/ciment (facteur B) ; et 36 %, 37 % et 38 % pour le facteur C. La résistance à la compression de chaque configuration expérimentale (composition de béton) est prédite en tenant compte des caractéristiques spécifiques de chaque composition, détaillées dans le Tableau 2. Le Tableau 5 présente les valeurs mesurées déterminées expérimentalement ainsi que les valeurs prédites correspondantes, obtenues à l'aide du modèle CatBoost.

Les résultats, illustrés à la Figure 3, comparent les valeurs prédites et mesurées de la résistance à la compression obtenues dans le DoE. Le mélange optimal parmi les neuf formulations de béton (expériences), telles que réalisées dans l'étude de Huang et al. (2024), est identifié sur la base d'une résistance maximale de 52,48 MPa (valeur prédite) et de 41,67 MPa (valeur mesurée), obtenue lorsque les facteurs A, B et C sont fixés à leur premier niveau.

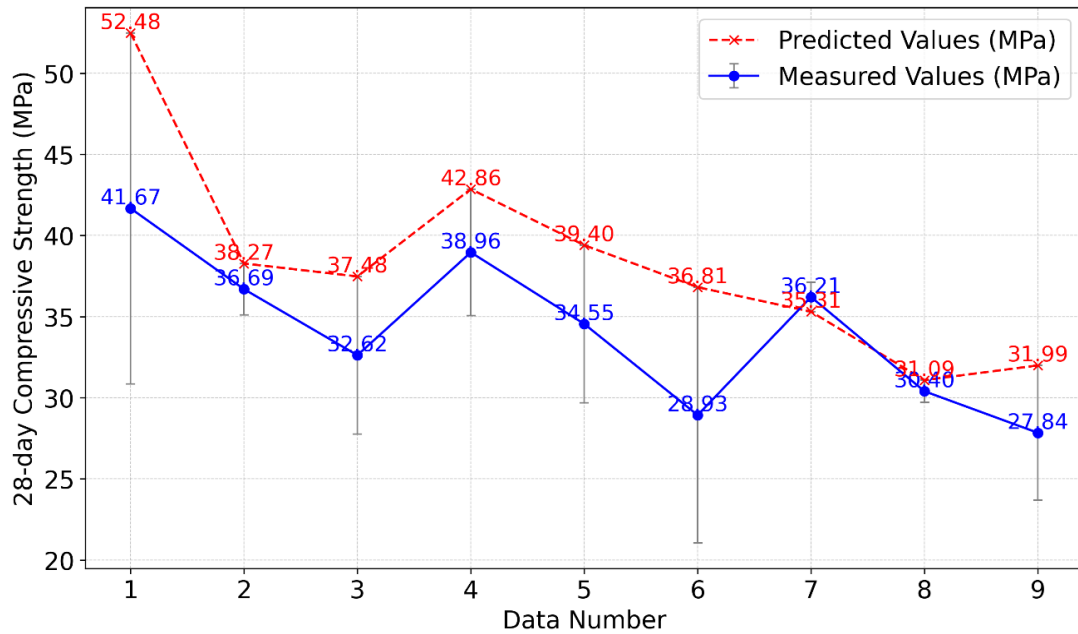


FIGURE 3. Valeurs prédites et mesurées pour la première étude de cas

Étant donné qu'un DoE fractionnaire avec neuf expériences a été réalisé, toutes les combinaisons possibles de facteurs (27 au total, correspondant à trois facteurs ayant chacun trois niveaux) n'ont pas été évaluées par Huang et al. (2024). Pour identifier les niveaux optimaux globaux, les effets principaux sont analysés en fonction des réponses moyennes du DoE. La Figure 4 présente les effets principaux des différentes configurations de mélange, montrant des résultats cohérents pour les valeurs prédites et mesurées. L'analyse indique que les niveaux optimaux sont atteints avec les facteurs A et B à leur premier niveau et le facteur C à son premier ou deuxième niveau due à son effet négligeable comparé aux facteurs A et B.

TABLEAU 5. Résistance à la compression mesurée et prédite (MPa) pour différentes configurations de mélange

A	B	C	Mesurée (MPa)	Prédite (MPa)	Erreur absolue (MPa)	Erreur relative (%)
1	1	1	41.67	52,48	10.81	25.94
1	2	3	36.69	38,27	1.58	4.31
1	3	2	32.62	37,48	4.86	14.90
2	1	3	38.96	42,86	3.90	10.01
2	2	2	34.55	39,4	4.85	14.04
2	3	1	28.93	36,81	7.88	27.24
3	1	2	36.21	35,31	0.90	2.49
3	2	1	30.40	31,09	0.69	2.27
3	3	3	27.84	31,99	4.15	14.91




FIGURE 4. Comparaison des valeurs des effets principaux mesurées (a) vs. prédites (b) pour les trois configurations de paramètres considérées dans l'étude.

B.2 Étude de cas 2

Dans la deuxième étude de cas, un DoE comportant dix-sept essais a été conduit. Les résultats, illustrés à la Figure 5, indiquent que la même composition de mélange, offrant la résistance à la compression la plus élevée, est identifiée pour les valeurs prédites et mesurées, soit 53,83 MPa et 49,41 MPa respectivement. Ce résultat démontre l'efficacité de la combinaison du DoE avec le modèle CatBoost pour identifier la composition optimale du mélange.




FIGURE 5. Valeurs prédites et mesurées pour la deuxième étude de cas

IV. CONCLUSION

Cette étude propose une approche novatrice combinant le DoE et l'apprentissage automatique avec le modèle CatBoost pour optimiser la conception des mélanges de BGR. À partir d'un ensemble de données de 594 compositions de BGR, le modèle CatBoost a démontré une précision prédictive élevée, atteignant un coefficient de détermination de 0,99 pour l'ensemble d'entraînement et de 0,88 pour l'ensemble de test.

L'approche combinée DoE-CatBoost a été validée à travers deux études de cas, confirmant son efficacité pour identifier les compositions optimales des mélanges permettant d'atteindre la résistance à la compression maximale. Les résultats soulignent le potentiel de cette méthode intégrée pour simplifier le processus de conception des mélanges en réduisant le nombre d'expériences nécessaires, et par conséquent, les coûts et le temps associés aux approches expérimentales traditionnelles.

Les recherches futures devraient viser à élargir l'ensemble de données et à explorer d'autres techniques d'apprentissage automatique pour améliorer la précision des prédictions et renforcer la capacité de généralisation du modèle à différents types de BGR et conditions expérimentales.

REFERENCES

P. Kumar Mehta, P. J. M. M. (2006). *Concrete (Microstructure, Properties, and Materials)* (Vol. 3). McGraw-Hill. <https://doi.org/DOI: 10.1036/0071462899>

Paulo J. Monteiro, Sabbie A. Miller, & Arpad Horvathand. (2017). Towards sustainable concrete. *Nature Materials*, 16, 698–699. <https://doi.org/https://doi.org/10.1038/nmat4930>

Yap, S. P., Chen, P. Z. C., Goh, Y., Ibrahim, H. A., Mo, K. H., & Yuen, C. W. (2018). Characterization of pervious concrete with blended natural aggregate and recycled concrete aggregates. *Journal of Cleaner Production*, 181, 155–165. <https://doi.org/10.1016/j.jclepro.2018.01.205>

de Larrard, F., & Colina, H. (Dir.). (2018). *Le béton recyclé. Marne-la-Vallée : Ifsttar, 2018. Ouvrages Scientifiques, OS14, ISBN 978-2-85782-747-4.*

Malhotra, V. M. (1976). Use of recycled concrete as a new aggregate. In *Proceedings of the Symposium on Energy and Resource Conservation in the Cement and Concrete Industry* (p. 39). CANMET.

Ben Chaabene, W., Flah, M., & Nehdi, M. L. (2020). Machine learning prediction of mechanical properties of concrete: Critical review. *Construction and Building Materials*, 260. <https://doi.org/10.1016/j.conbuildmat.2020.119889>

Françoid de Larrard. (1999). *Concrete Mixture Proportioning : A scientific Approach* (E. & F.N. Spon). <http://www.lcpc.fr/betonlabpro>

Bensaber, A., Boudaoud, Z., Seghir, N. T., Czarnecki, S., & Sadowski, Ł. (2023). The assessment of concrete subjected to compressive and flexural preloading using nondestructive testing methods, correlation between concrete strength and combined method (SonReb). *Measurement*, 222. <https://doi.org/10.1016/j.measurement.2023.113659>

Chen, J., Zhou, Y., & Yin, F. (2022). A practical equation for the elastic modulus of recycled aggregate concrete. *Buildings*, 12. <https://doi.org/10.3390/buildings12020187>

Ding, W., Abdel-Basset, M., Hawash, H., & Ali, A. M. (2022). Explainability of artificial intelligence methods, applications and challenges: A comprehensive survey. *Information Sciences*, 615, 238-292. <https://doi.org/10.1016/j.ins.2022.10.013>

Gao, Y., Li, Z., Li, Y., Zhu, Z., & Zhu, J. (2023). Development of chemistry-informed interpretable model for predicting compressive strength of recycled aggregate concrete containing supplementary cementitious materials. *Journal of Cleaner Production*, 425. <https://doi.org/10.1016/j.jclepro.2023.138733>

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>

Han, S. H., Khayat, K. H., Park, S., & Yoon, J. (2023). Machine learning-based approach for optimizing mixture proportion of recycled plastic aggregate concrete considering compressive strength, dry density, and production cost. *Journal of Building Engineering*. <https://doi.org/10.1016/j.jobe.2023.108393>

Hancock, J. T., & Khoshgoftaar, T. M. (2020). CatBoost for big data: An interdisciplinary review. *Journal of Big Data*, 7. <https://doi.org/10.1186/s40537-020-00369-8>

Huang, P., Dai, K., & Yu, X. (2023). Machine learning approach for investigating compressive strength of self-compacting concrete containing supplementary cementitious materials and recycled aggregate. *Journal of Building Engineering*, 79. <https://doi.org/10.1016/j.jobe.2023.107904>

Huang, Y., Zhang, Y., Ma, T., Xiang, X., Chen, W., Ren, X., & Wu, J. (2024). Study on the mechanical properties and deterioration mechanism of recycled aggregate concrete for low-grade highway pavements. *Construction and Building Materials*, 415. <https://doi.org/10.1016/j.conbuildmat.2024.135112>

Hunter, J. D. (2007). Matplotlib: A 2D graphics environment. *Computing in Science and Engineering*, 9, 90-95.

Katz, A. (2003). Properties of concrete made with recycled aggregate from partially hydrated old concrete. *Cement and Concrete Research*, 33, 703-711. [https://doi.org/10.1016/S0008-8846\(02\)01033-5](https://doi.org/10.1016/S0008-8846(02)01033-5)

Khan, M. I., & Abbas, Y. M. (2023). Intelligent data-driven compressive strength prediction and optimization of reactive powder concrete using multiple ensemble-based machine learning approach. *Construction and Building Materials*, 404. <https://doi.org/10.1016/j.conbuildmat.2023.133148>

Luan, C., Wang, Q., Yang, F., Zhang, K., Utashev, N., Dai, J., & Shi, X. (2021). Practical prediction models of tensile strength and reinforcement-concrete bond strength of low-calcium fly ash geopolymer concrete. *Polymers*, 13. <https://doi.org/10.3390/polym13060875>

Mai, H. V. T., Nguyen, M. H., & Ly, H. B. (2023a). Development of machine learning methods to predict the compressive strength of fiber-reinforced self-compacting concrete and sensitivity analysis. *Construction and Building Materials*, 367. <https://doi.org/10.1016/j.conbuildmat.2023.130339>

Mai, H. V. T., Nguyen, M. H., Trinh, S. H., & Ly, H. B. (2023b). Toward improved prediction of recycled brick aggregate concrete compressive strength by designing ensemble machine learning models. *Construction and Building Materials*, 369. <https://doi.org/10.1016/j.conbuildmat.2023.130613>

Nelli, F. (2015). *Python Data Analytics: Data Analysis and Science Using Pandas, Matplotlib, and the Python Programming Language*. Apress. <https://doi.org/10.1007/978-1-4842-0958-5>

Pal, A., Ahmed, K. S., Hossain, F. Z., & Alam, M. S. (2023). Machine learning models for predicting compressive strength of fiber-reinforced concrete containing waste rubber and recycled aggregate. *Journal of Cleaner Production*, 423. <https://doi.org/10.1016/j.jclepro.2023.138673>

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... & Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*.

Picard, R. R., & Cook, R. D. (1984). Cross-validation of regression models. *Journal of the American Statistical Association*.

Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A. V., & Gulin, A. (2017). CatBoost: Unbiased boosting with categorical features.

Dorogush, A. V., Ershov, V., & Yandex, A. G. (2017). CatBoost: gradient boosting with categorical features support. Workshop on ML Systems at NIPS. <https://github.com/Microsoft/LightGBM>

Quan Tran, V., Quoc Dang, V., & Si Ho, L. (2022). Evaluating compressive strength of concrete made with recycled concrete aggregates using machine learning approach. *Construction and Building Materials*, 323. <https://doi.org/10.1016/j.conbuildmat.2022.126578>

Salehi, H., & Burgueño, R. (2018). Emerging artificial intelligence methods in structural engineering. *Engineering Structures*. <https://doi.org/10.1016/j.engstruct.2018.05.084>

Wu, Y., & Zhou, Y. (2022). Hybrid machine learning model and Shapley additive explanations for compressive strength of sustainable concrete. *Construction and Building Materials*, 330. <https://doi.org/10.1016/j.conbuildmat.2022.127298>

Zhang, X., Zeshan Akber, M., Poon, C. S., & Zheng, W. (2023). Predicting the 28-day compressive strength by mix proportions: Insights from a large number of observations of industrially produced concrete. *Construction and Building Materials*, 400. <https://doi.org/10.1016/j.conbuildmat.2023.132754>