

Utilisation de l'intelligence artificielle pour l'optimisation multi-critères des bétons autoplaçants

Abdelhamid Hafidi^{1,2,3}, Benoit Hilloulin¹, Ilhame Harbouz^{1,4}, Ahmed Loukili¹, Ammar Yahia^{3,5}

1 Nantes Université, Ecole Centrale Nantes, CNRS, GeM, UMR 6183, F-44000 Nantes, France

2 Edycem, 3 Rue Nicolas Sadi Carnot, 85600 Montaigu-Vendée

3 Université de Sherbrooke, Department of Building and Civil Engineering, Sherbrooke, J1K 2R1, Québec, Canada

4 Green Tech Institute (GTI), Mohammed VI Polytechnic University (UM6P), Benguerir, 43150, Morocco

5 Canadian Dubai University, Department of Architecture, Dubai, UAE

RÉSUMÉ

Dans cette étude, un outil d'optimisation des propriétés rhéologiques des bétons autoplaçants (BAP) est proposé. Des modèles d'apprentissage automatique ont été développés pour prédire avec précision la viscosité et le seuil d'écoulement. L'objectif principal est de générer, par le biais d'un apprentissage automatique supervisé, un modèle offrant une formulation à faible empreinte carbone, répondant aux exigences éco-rhéo-mécaniques des utilisateurs. Afin de respecter les exigences écologiques du béton, les additions minérales telles que le laitier, les cendres volantes et les fillers calcaires émergent comme des solutions prometteuses pour réduire les émissions de carbone dans l'industrie du ciment. Cependant, leur intégration peut modifier les propriétés rhéologiques du béton, impactant directement ses caractéristiques mécaniques et sa durabilité. La prédiction de ces propriétés est complexe en raison de l'interaction de plusieurs facteurs. Pour relever ce défi, des modèles d'apprentissage automatique tels que « Random Forest », « Gradient Boosting », « Extrême Gradient Boosting » et « Light Gradient Boosted Machine » ont été utilisés pour prédire ces propriétés rhéologiques. Une base de données exhaustive, englobant 17 paramètres d'entrée tels que les proportions du mélange, les caractéristiques des granulats et les propriétés rhéologiques, a été collectée à partir de la littérature existante. L'analyse des performances de ces modèles a révélé que le Random Forest excelle dans la prédiction de la viscosité et du seuil d'écoulement. La programmation génétique a été utilisée afin d'optimiser les mélanges des BAPs en suivant des contraintes imposées par l'utilisateur sur les entrées du modèle.

Mots-clefs Apprentissage automatique, bétons autoplaçants, empreinte carbone, intelligence artificielle, optimisation, rhéologie.

I. INTRODUCTION

Le béton est le matériau de construction le plus utilisé dans le monde, en raison de ses nombreux avantages, notamment sa maniabilité, sa résistance, sa durabilité et sa rentabilité. Cependant, la production de ciment, un composant essentiel de la fabrication du béton, a une empreinte carbone considérable (Karim et al., 2011; Kovačević et al., 2022; Thomas et al., 2021). Face aux préoccupations croissantes concernant les changements climatiques et la réduction des émissions de gaz à effet de serre, l'industrie du ciment recherche activement des solutions pour atténuer son impact sur l'environnement tout en répondant aux exigences toujours croissantes de la construction. Dans ce contexte, les additions minérales sont apparues comme une alternative prometteuse, offrant la possibilité de réduire de manière significative les émissions de CO₂ associées à la production de ciment. Cependant, cette substitution peut entraîner des modifications des propriétés rhéologiques du béton (Boukendakdji et al., 2009 ; Li et al., 2018 ; Slavcheva et al., 2020) ce qui, par conséquent, peut impacter son comportement mécanique et sa durabilité (Neville, 2004 ; Kovler and Roussel, 2011).

L'impact de ces additions sur les propriétés rhéologiques varie en fonction de plusieurs facteurs, tels que le pourcentage de remplacement du ciment, les propriétés physiques des additions et leur composition chimique (Mandal et al., 2023). Les propriétés les plus documentées du béton frais sont la viscosité et le seuil d'écoulement. Tenant compte de la synergie entre les différents facteurs influant le comportement des nouveaux bétons bas carbone, une approche purement expérimentale ne sera pas suffisante pour assurer une compréhension approfondie des propriétés du béton. Pour remédier à cela, plusieurs applications des techniques d'apprentissage automatique en génie civil ont été explorées, commençant par la prédiction des propriétés physiques du béton, telles que le retrait (Hilloulin et al., 2022b) et le fluage (Liang et al., 2022), ainsi que la détection des bulles d'air à l'aide de réseaux neuronaux artificiels (Hilloulin et al., 2022a). De plus, des techniques d'apprentissage automatique ont été utilisées dans la prédiction des propriétés mécaniques du béton autoplaçant incorporant des additions minérales (Sonebi and Cevik, 2009; Sonebi et al., 2013). Cette étude vise à démontrer le potentiel des modèles d'apprentissage automatique les plus performants dans la prédiction des propriétés rhéologiques, notamment le seuil d'écoulement et la viscosité. Pour ce faire, une base de données a été constituée à partir de la littérature, et les résultats obtenus à partir des modèles d'apprentissage automatique ont été examinés en détails. Enfin, le modèle le plus prometteur est ensuite utilisé pour optimiser les formulations des BAP, en tenant compte des considérations rhéologiques, mécaniques et environnementales.

II. METHODOLOGIE DE MODELISATION

A. Méthodologie de la modélisation

La méthodologie de la modélisation est présentée dans la **FIGURE 1**. Elle comprend quatre étapes principales : (I) l'établissement et la description de la base de données, (II) le prétraitement des données, (III) l'identification du modèle d'apprentissage automatique optimal avec la meilleure

performance, (IV) la prédiction de la viscosité et du seuil d'écoulement suivie d'une analyse d'optimisation des mélanges (**FIGURE 1**).

Le processus de création de la base de données a impliqué une revue approfondie de la littérature, à laquelle ont été ajoutées les valeurs de la résistance mécanique et le bilan carbone, guidant la sélection de 17 paramètres en tant qu'entrées du modèle, avec la viscosité plastique et le seuil d'écoulement désignés comme variables de sortie. Au cours de l'étape II, les données ont subi un traitement approfondi pour améliorer la qualité et l'exhaustivité de la base de données. À l'étape III, l'ensemble de données a été divisé de manière aléatoire en un ensemble de test de 20 % et un ensemble d'entraînement de 80 %. Les modèles « Random Forest (RF) », « Gradient Boosting (GB) », « Extreme Gradient Boosting (XGB) », et « Light Gradient Boosted Machine (LGBM) », qui seront définis dans les sections suivantes, ont été entraînés. Leurs performances ont été évaluées à l'aide de quatre indicateurs statistiques : le coefficient de détermination (R^2), la racine carrée de l'erreur quadratique moyenne, l'erreur absolue moyenne et l'erreur absolue moyenne en pourcentage, qui seront également définis par la suite. Enfin, le modèle d'apprentissage automatique le plus adapté a été utilisé pour prédire à la fois la viscosité plastique et le seuil d'écoulement et l'optimisation de la formulation du mélange.

B. Collecte de la base de données

Description de la base de données

Cette étude présente une approche globale d'optimisation des mélanges des BAP sur la base des propriétés rhéologiques. Celle-ci implique la construction d'une base de données complète à partir de la littérature. L'ensemble des données intègre diverses caractéristiques, telles que les proportions des constituants, les propriétés rhéologiques, la résistance mécanique, le bilan carbone de 177 formulations de BAP et couvrant plus de 17 paramètres de mélange. L'ensemble des données a fait l'objet d'un prétraitement, prenant en compte les entrées manquantes et l'homogénéisation des données. Les valeurs manquantes des entrées comme la densité des granulats ou leur taille maximale ont été remplacées par la moyenne des valeurs disponibles (**TABLEAU 1**). La normalisation de tous les paramètres a permis d'assurer l'homogénéité de l'ensemble de données.

La base de données construite couvre une large gamme de valeurs, englobant différentes additions minérales. Afin de faciliter la création des modèles d'apprentissage automatique pour prédire le seuil d'écoulement et la viscosité, l'ensemble de données a été divisé en sous-ensembles d'entraînement (80 % de la base de données) et de test (20 % de la base de données) qui servent à l'évaluation des performances en comparant les prédictions du modèle aux valeurs expérimentales réelles. Le **TABLEAU 1** présente une analyse statistique de la base de données.

Préparation des données de la résistance, empreinte carbone

Comme la modélisation est basée sur la prédiction des propriétés rhéologiques, la base de données initiale ne contenait pas les valeurs de la résistance mécanique à 28 jours (fc_{28}) et l'empreinte carbone des matériaux. Pour remédier à cela, une analyse mécanique et environnementale a été réalisée afin de compléter la base de données. Les valeurs de fc_{28} ont été prédites en utilisant un modèle d'apprentissage automatique appelé XGB (décrit dans la section suivante), qui a été entraîné et testé

sur une base de plus de 1000 données (I-Cheng Yeh, 2007). Le modèle a montré une précision acceptable, avec un coefficient de détermination R^2 de 83 %.

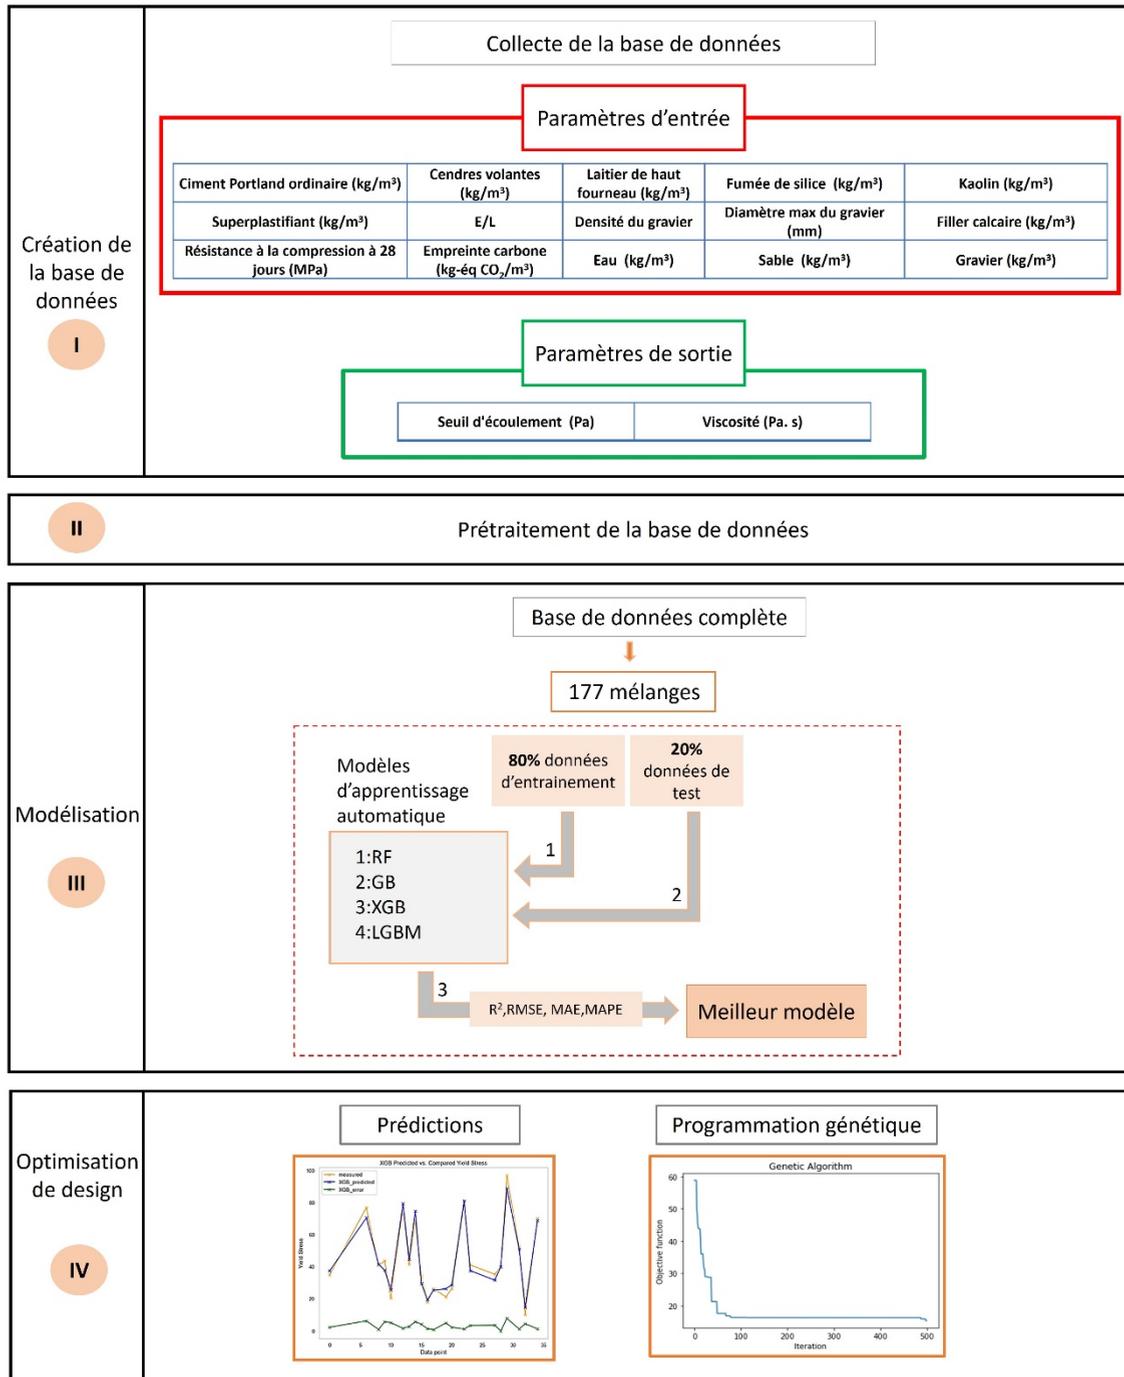


FIGURE 1 - Méthodologie de la modélisation

En ce qui concerne l'empreinte carbone, le choix des facteurs d'émission liés à la production s'est principalement basé sur les données de l'Agence de la transition écologique (ADEME) (" Bilans GES - ADEME", 2023) sans tenir compte du détail du transport. Le **TABLEAU 2** présente les facteurs d'émission de chaque composant du béton.

TABLEAU 1 - Description de base de données

	Moyenne	Écart type	Min	Max
Ciment Portland ordinaire (kg/m ³)	377,34	81,01	164,5	650,0
Cendres volantes (kg/m ³)	10,86	35,59	0,0	163,5
Laitier de haut fourneau (kg/m ³)	7,50	27,56	0,0	258,0
Fumée de silice (kg/m ³)	17,63	29,36	0,0	156,0
Kaolin (kg/m ³)	10,51	26,55	0,0	128,5
Filler calcaire (kg/m ³)	31,75	64,62	0,0	211,5
Gravier (kg/m ³)	866,65	44,45	761,0	928,3
Sable (kg/m ³)	889,66	39,21	714,0	930,0
Eau (kg/m ³)	181,63	16,51	147,8	200,0
Superplastifiant (kg/m ³)	5,16	2,50	1,50	13,76
Rapport Eau sur Liants (E/L)	0,44	0,08	0,28	0,64
Densité du gravier	2,68	0,06	2,64	2,89
Diamètre max du gravier (mm) CA	12,5	3,3	10,0	20,0
Seuil d'écoulement (Pa)	42,6	29,0	2,2	154,3
Viscosité (Pa.s)	77,5	49,0	8,4	189,0
Résistance à la compression à 28 jours (MPa)	43,2	11,9	20,9	68,8
Empreinte carbone (kg-éq CO ₂ /m ³)	414,8	82,6	196,7	696,5

TABLEAU 2 - Données sur l'empreinte carbone des matériaux (" Bilans GES - ADEME", 2023)

	Empreinte carbone (kg-éq CO₂/kg)
Ciment	1,043
Cendres Volantes	0,00397
Laitier de haut fourneau	0,14705
Fumée de silice	0,00397
Kaolin	0,1
Filler calcaire	0,8
Gravier	0,00503
Sable	0,0053
Superplastifiant	1,884

C. Modèles d'apprentissage automatique

Les quatre modèles d'intelligence artificielle intégrés dans cette étude, sont unanimement reconnus comme étant particulièrement efficaces dans la prédiction et l'optimisation dans le domaine de la mécanique et du génie civil (Liang et al., 2022). Les particularités de chaque modèle sont décrites ci-dessous.

Random Forest (RF), introduit initialement par Breiman (Breiman, 2001), est un algorithme d'apprentissage automatique supervisé largement utilisé pour les tâches de classification et de régression. RF combine les principes de l'agrégation Bootstrap et du sous-espace aléatoire (Breiman, 2001). Il se compose de nombreux arbres de décision indépendants, chacun construit à l'aide d'un processus stochastique. Initialement, la procédure implique plusieurs cycles d'échantillonnage Bootstrap, où un sous-ensemble aléatoire d'entrées est sélectionné à chaque cycle d'échantillonnage, pouvant potentiellement conduire à la formation de plusieurs arbres de décision. La prédiction du modèle RF est finalement déterminée par un processus de vote ou de moyenne basé sur les résultats de ces arbres de décision.

Le gradient boosting (GB) est une technique qui améliore les performances d'un modèle fort en combinant plusieurs modèles faibles. Initialement développé pour résoudre des problèmes de classification, le GB a été étendu à la régression par Friedman (Friedman, 2001). Dans cette approche, l'algorithme prend en compte les erreurs commises par les arbres précédents à chaque itération, cherchant à minimiser ces erreurs lors de la construction de l'estimateur suivant. En conséquence, l'erreur globale dans l'ensemble des arbres diminue progressivement. Le GB est ancré dans le concept de boosting, qui implique l'utilisation de diverses combinaisons de modèles caractérisés par une polarisation élevée et une faible variance. Il construit à la fois des arbres peu profonds et profonds en utilisant le même ensemble de données.

Extreme Gradient Boosting (XGB) forme séquentiellement une série d'apprenants faibles. XGBoost adopte une approche d'entraînement pour créer un apprenant fort. À chaque étape, un algorithme d'optimisation de descente de gradient est utilisé pour entraîner un apprenant faible, visant à minimiser la fonction de perte. XGB intègre une génération de modèles plus adaptée que d'autres modèles, ce qui le rend plus efficace dans le contrôle du sur-apprentissage. Cette méthode améliorée de gradient boosting utilise la dérivée du premier ordre pour l'optimisation, mais elle étend également la fonction de perte du second ordre des dérivées de Taylor, exploitant à la fois les dérivées du premier et du second ordre.

LightGBM (LGBM) est une technique d'apprentissage automatique relativement récente basée sur des arbres de décision, introduite par Microsoft et similaire à XGB. Cependant, elle présente quelques différences notables dans sa méthode de construction des arbres. Contrairement à la plupart des modèles basés sur des arbres qui développent l'arborescence horizontalement, LGBM adopte une stratégie de développement vertical en construisant les arbres par feuilles. Cette approche permet à LGBM de choisir la feuille ayant le plus grand potentiel de réduction des pertes à chaque étape de la construction de l'arbre, réduisant ainsi le coût des prédictions incorrectes. De plus, en limitant la profondeur des arbres, LGBM parvient à éviter le sur-apprentissage, ce qui en fait un choix attrayant pour de nombreux problèmes d'apprentissage automatique. Cependant, il convient de noter que le grand nombre d'hyperparamètres associés à LGBM peut rendre le processus de réglage plus complexe par rapport à d'autres méthodes.

D. Indicateurs statistiques

Afin d'évaluer les performances du modèle, diverses métriques statistiques peuvent être utilisées. Dans cette étude, quatre indices métriques clés ont été utilisés : l'erreur absolue moyenne MAE, le coefficient de détermination (R^2), la racine carrée de l'erreur quadratique moyenne (RMSE) et l'erreur absolue moyenne en pourcentage (MAPE).

Erreur absolue moyenne (MAE). L'erreur absolue moyenne est décrite comme la moyenne des écarts entre les valeurs prédites et les valeurs expérimentales réelles dans l'ensemble de données. L'expression de la MAE est la suivante :

$$MAE = \frac{1}{N} \sum |e_i - \hat{e}_i| \quad (1)$$

Racine carrée de l'erreur quadratique moyenne (RMSE). La racine carrée de l'erreur quadratique moyenne est une métrique couramment utilisée pour évaluer l'exactitude d'un modèle dans la prédiction de données numériques. Sa définition est la suivante :

$$RMSE = \sqrt{\frac{1}{N} \sum (e_i - \hat{e}_i)^2} \quad (2)$$

Coefficient de détermination (R^2). Le coefficient de détermination est une métrique statistique utilisée pour évaluer dans quelle mesure les variations d'une variable peuvent être expliquées par les variations d'une deuxième variable. R^2 est défini comme suit :

$$R^2 = 1 - \frac{\sum (e_i - \hat{e}_i)^2}{\sum (e_i - \bar{e})^2} \quad (3)$$

Erreur absolue moyenne en pourcentage (MAPE). L'erreur absolue en pourcentage est une mesure couramment utilisée pour évaluer la fiabilité d'un modèle en termes de différence entre les valeurs réelles et estimées. La MAPE est défini comme suit :

$$MAPE = \frac{1}{N} \sum \frac{|e_i - \hat{e}_i|}{|e_i|} \quad (4)$$

La variable e_i représente la valeur d'expansion du i -ème point de données dans la base de données, tandis que \hat{e}_i représente la valeur prédite correspondant au i -ème point d'échantillon dans le modèle. Le symbole \bar{e} représente la moyenne des valeurs mesurées. N représente le nombre des mesures.

E. Programmation génétique

La Programmation Génétique (PG) est une extension des Algorithmes Génétiques proposée par Koza ("Genetic Programming," 1992). Ce pionnier de cette approche la définit comme une méthode de résolution de problèmes indépendante du domaine, dans laquelle des programmes informatiques sont évolués pour résoudre, ou approximativement résoudre, des problèmes basés sur le principe darwinien de la reproduction et de la survie des plus aptes, ainsi que sur des analogues des opérations génétiques naturelles telles que le croisement et la mutation. La PG est devenue un outil très utilisé dans le domaine des matériaux de construction. C'est un outil permettant de faire un choix judicieux parmi les mélanges de BAPs qui vont être étudiés au laboratoire, selon les conditions et les contraintes fixées par l'utilisateur. Elle permet également de

concevoir des bétons non ordinaires présentant des performances significatives qui méritent d'être testées en laboratoire. La PG reproduit des programmes informatiques pour résoudre des problèmes en exécutant les étapes suivantes :

1. Génération d'une population initiale de fonctions et de terminaux du problème (programmes informatiques).
2. Exécution de chaque programme dans la population et attribution du fitness, une mesure évaluant à quel point une solution individuelle dans la population est adaptée ou performante par rapport à l'objectif de l'optimisation.
3. Répétition de l'étape 2 pour de nouveaux programmes informatiques.
4. Sélection du meilleur programme existant, qui est présenté comme le résultat de la programmation génétique.

III. RESULTATS DES MODELES D'APPRENTISSAGE AUTOMATIQUE

La FIGURE 2 présente une étude comparative des différents modèles selon les quatre métriques, respectivement pour le seuil d'écoulement et la viscosité plastique.

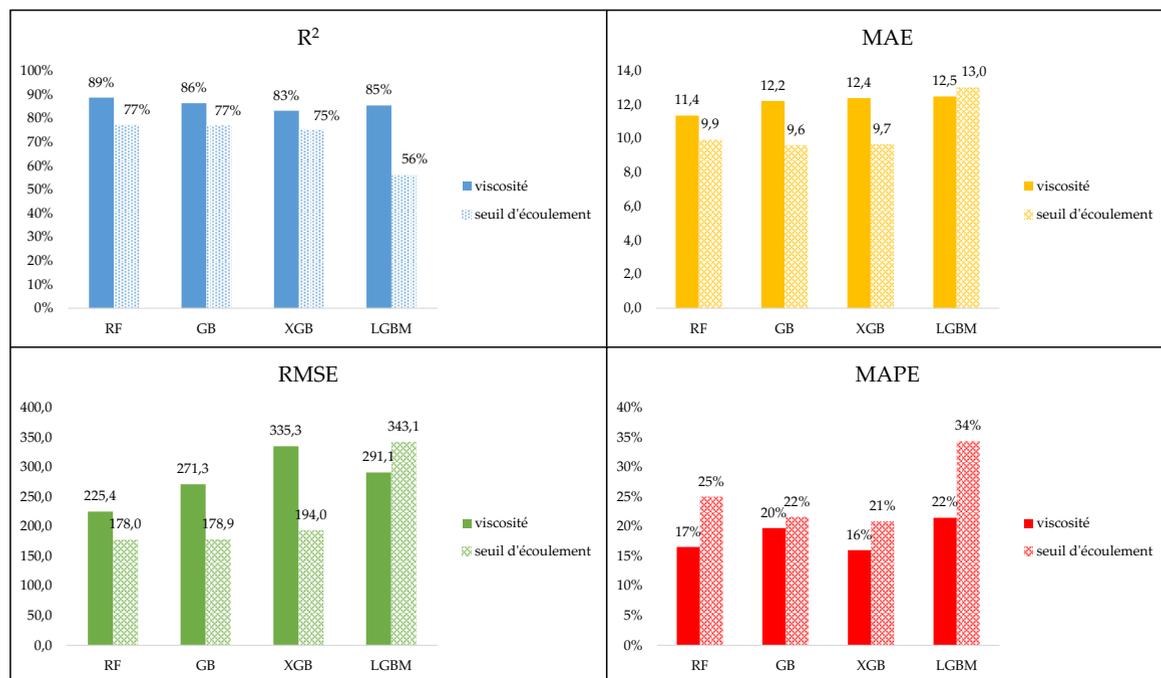


FIGURE 2. Comparaison des modèles pour le seuil d'écoulement et la viscosité

Le modèle RF se démarque avec les meilleures performances en termes de R² et RMSE, affichant respectivement des valeurs de 77,2 % et 178 Pa pour le seuil d'écoulement, ainsi que 88,7 % et 225,4 Pa.s pour la viscosité plastique. En ce qui concerne le MAE, le modèle GB affiche la valeur la plus basse, atteignant 9,6 Pa pour le seuil d'écoulement, tandis que le modèle RF excelle également pour la viscosité avec une valeur de MAE de 11,4 Pa.s. En ce qui concerne le MAPE, le modèle XGB se distingue avec des résultats exceptionnels, affichant des valeurs de 20,9 % pour le seuil d'écoulement et environ 16,0 % pour la viscosité. Ces performances remarquables sont suivies par

le modèle GB avec un MAPE de 21,6 % pour le seuil d'écoulement et 19,8 % pour la viscosité. En revanche, le modèle LGBM présente des performances inférieures par rapport aux autres modèles. En prenant en considération l'ensemble de ces métriques, le modèle RF semble être le plus approprié pour la prédiction du seuil d'écoulement et de la viscosité plastique dans ce contexte spécifique. Par la suite ce modèle a été utilisé pour optimiser les mélanges en fonction d'un seuil d'écoulement et d'une viscosité donnés.

Les valeurs de RMSE pour la viscosité et le seuil d'écoulement sont élevées, ce qui peut être attribué à plusieurs facteurs, principalement le nombre limité des entrées dans notre modèle. Ce paramètre est difficile à modifier étant donné que la base de données est principalement constituée de la littérature existante. De plus, un deuxième paramètre impactant ces propriétés est le fait que la base de données contienne des bétons avec un taux élevé de substitution de ciment par des additions minérales. Cela rend la prédiction des propriétés rhéologiques de ces bétons particulièrement difficile, contribuant ainsi à l'augmentation du RMSE et la précision globale des modèles.

Le travail présenté dans cet article sera complété par une étude plus détaillée, au cours de laquelle la base de données sera élargie avec d'autres entrées. Cette approche permettra de réduire significativement le RMSE. La **FIGURE 3** illustre la relation entre les valeurs prédites et les valeurs mesurées. On observe une excellente précision du modèle RF pour les données d'entraînement. Concernant les données de test, le modèle produit des résultats satisfaisants et acceptables compte tenu de la complexité du problème et des facteurs mentionnés précédemment (entrées limitées etc). Bien que la valeur RMSE soit relativement élevée, ce modèle peut être utilisé pour prédire le comportement rhéologique des BAPs. Des améliorations supplémentaires pourraient être apportées au modèle dans une étude ultérieure.

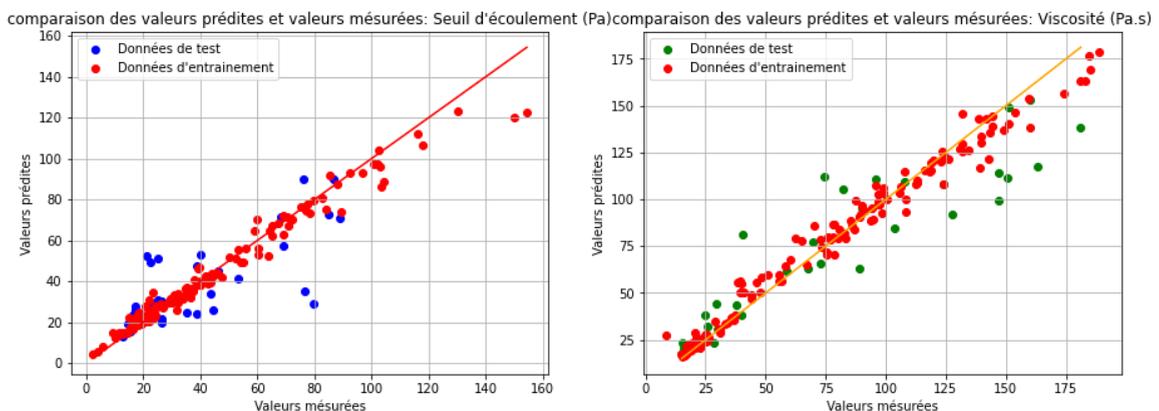


FIGURE 3. Comparaison entre les valeurs prédites est mesurées pour le modèle RF

V. PROGRAMMATION GENETIQUE

Dans cette section, une étude d'optimisation visant à créer un modèle prédictif est présentée. Ce modèle, basé sur les valeurs cibles de viscosité et de seuil d'écoulement, a pour objectif de proposer une formulation qui répond à la fois aux exigences rhéologiques, mécaniques et environnementales. Nous utilisons le modèle RF élaboré dans la section précédente qui présente le meilleur R^2 . Pour

assurer une optimisation efficace, des choix judicieux pour les valeurs limites ont été faits pour les paramètres d'entrées. Ceci garantit que le modèle de programmation génétique ne produit pas des valeurs extrêmes. Les valeurs maximales et minimales des paramètres des formulations optimisées sont répertoriées dans le **TABLEAU 3**. Le modèle de programmation génétique exécute 1000 itérations pour déterminer le béton (la formulation) le plus optimisé. L'objectif était d'obtenir une erreur globale (somme des erreurs de viscosité et de seuil d'écoulement) entre les valeurs cibles et les valeurs prédites inférieure à 1%, tout en respectant les valeurs extrêmes des paramètres de mélange du **TABLEAU 3**. Le temps d'exécution du modèle, réalisé sur un processeur Intel i5 de 12e génération, a été d'environ 15 secondes. L'erreur globale observé est moins de 1% entre les valeurs cibles et les valeurs prédites.

TABLEAU 3 - Valeurs limites pour l'optimisation des mélanges

	Min	Max
Ciment Portland ordinaire (kg/m ³)	0	400
Cendres volantes (kg/m ³)	0	100
Laitier de haut fourneau (kg/m ³)	0	100
Fumée de silice (kg/m ³)	0	100
Kaolin (kg/m ³)	0	100
Filler calcaire (kg/m ³)	0	100
Gravier (kg/m ³)	0	1400
Sable (kg/m ³)	0	1400
Eau (kg/m ³)	0	400
Superplastifiant (kg/m ³)	0	20
E/L	0	0,5
Densité du gravier	2,2	2,8
Diamètre max du gravier (mm)	0	50
Résistance à la compression à 28 jours (MPa)	30	80
Empreinte carbone (kg-éq CO ₂ /m ³)	100	300

V. FACTEURS INFLUENTS

Dans cette partie, une étude d'impact est présentée afin de déterminer l'effet des paramètres d'entrée sur la viscosité et le seuil d'écoulement. Pour cela, un outil d'intelligence artificielle appelé "SHapley Additive exPlanations" (SHAP) est utilisé. **La Figure 4** illustre l'impact des facteurs sur le seuil d'écoulement et sur la viscosité. Les facteurs sont classés par ordre décroissant selon leur influence de haut en bas. Si la couleur d'un facteur est magenta du côté droit de l'axe des ordonnées, cela signifie que la sortie (dans notre cas, les paramètres rhéologiques) augmente avec l'augmentation du facteur en question. Si la couleur est bleue, cela signifie que la sortie augmente avec la diminution du facteur en question. A contrario, si la couleur est magenta du côté gauche, cela signifie que la sortie diminue avec l'augmentation du facteur. Si la couleur est bleue du côté gauche, cela signifie que la sortie diminue avec la diminution du facteur en question.

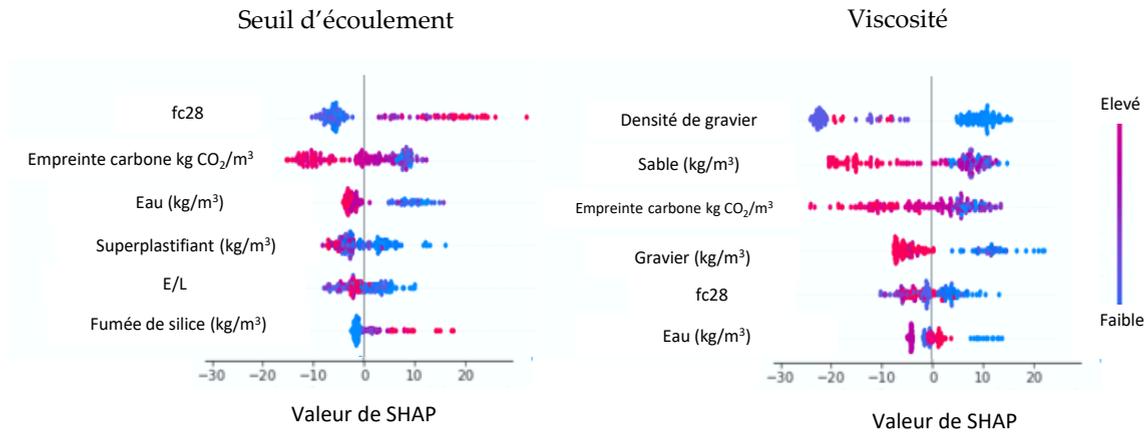


FIGURE 4. Impact des paramètres d'entrée sur les propriétés rhéologiques

Parmi les 17 paramètres d'entrée, le fc_{28} , l'empreinte carbone, la quantité d'eau et le superplastifiant sont les paramètres ayant le plus d'impact sur le seuil d'écoulement. Plus le fc_{28} est élevé, plus le seuil d'écoulement est élevé, entraînant un béton plus ferme et une perte de facilité de mise en place des BAP. En ce qui concerne l'empreinte carbone, plus elle est élevée, plus le seuil d'écoulement est faible, posant ainsi un questionnement pour réduire l'impact environnemental des BAP. Pour la quantité d'eau et le superplastifiant, l'effet est bien clair ; plus il y a d'eau, plus le seuil d'écoulement diminue ce qui montre que le modèle est en cohérence avec la réalité. En ce qui concerne la viscosité, les granulats et leurs caractéristiques, l'empreinte carbone, sont les paramètres les plus importants.

VI. CREATION D'INTERFACE

Afin de simplifier l'utilisation, que ce soit du modèle d'apprentissage automatique ou de l'algorithme génétique, une interface a été créée. Cette interface permet à l'utilisateur soit de fournir les propriétés de mélange pour prédire le seuil d'écoulement et la viscosité plastique, soit de demander à l'utilisateur de fournir les valeurs cibles des paramètres rhéologiques pour optimiser les mélanges. Cette interface repose sur les modèles que nous venons de détailler dans les parties précédentes, offrant ainsi des informations pertinentes et suffisantes sur le mélange. Elle propose une vision de la granulométrie, de l'adjuvantation, de la résistance et de l'empreinte carbone, offrant ainsi une vue complète qui permet à l'utilisateur de faire un choix judicieux quant au béton à formuler ou à tester dans le laboratoire. Actuellement en cours de développement, cette interface vise à intégrer d'autres fonctionnalités comme l'affaissement et l'étalement, ainsi que des paramètres de résistance au jeune âge, de durabilité et enfin l'impact de ces paramètres sur les propriétés recherchées.

VII. CONCLUSIONS

Dans cette étude, quatre modèles d'apprentissage automatique ont été utilisés pour prédire la viscosité plastique et le seuil d'écoulement des bétons autoplaçants. L'objectif ultime était de créer un modèle prédictif capable d'optimiser les formulations de bétons autoplaçants, offrant ainsi une

vision globale du comportement rhéologique, des propriétés mécaniques et écologique du béton. Les conclusions de cette étude peuvent être résumées comme suit :

- Une base de données composée de 177 formulations de bétons autoplaçants, incluant 17 paramètres, a été recueillie à partir de la littérature existante.
- Les quatre modèles utilisés (Random Forest, Gradient Boosting, Extreme Gradient Boosting et LightGBM) ont démontré des performances élevées dans la prédiction des propriétés des BAP.
- Le modèle Random Forest s'est distingué comme étant le plus performant, avec un coefficient de détermination (R^2) de 77.2% pour le seuil d'écoulement et de 88.7% pour la viscosité plastique.
- Un algorithme génétique a été développé en se basant sur les modèles d'apprentissage automatique les plus performants afin d'optimiser la formulation des bétons autoplaçants.
- Une interface interactive a été conçue pour permettre la prédiction des paramètres rhéologiques et l'optimisation des mélanges, offrant ainsi une utilisation conviviale des modèles d'apprentissage automatique.

Cette étude s'inscrit dans une approche visant à optimiser les caractéristiques du béton de manière écologique, en cherchant à respecter les enjeux environnementaux tout en favorisant une transition écologique efficace et conforme aux défis actuels.

REFERENCES

- Boukendakdji, O., Kenai, S., Kadri, E.H., Rouis, F., 2009. Effect of slag on the rheology of fresh self-compacted concrete. *Constr. Build. Mater.* 23, 2593–2598. <https://doi.org/10.1016/j.conbuildmat.2009.02.029>
- Breiman, L., 2001. Random Forests. *Mach. Learn.* 45, 5–32. <https://doi.org/10.1023/A:1010933404324>
- Friedman, J.H., 2001. Greedy function approximation: A gradient boosting machine. *Ann. Stat.* 29. <https://doi.org/10.1214/aos/1013203451>
- Genetic Programming [WWW Document], 1992. MIT Press. URL <https://mitpress.mit.edu/9780262527910/genetic-programming/> (accessed 2.5.24).
- Hilloulin, B., Bekrine, I., Schmitt, E., Loukili, A., 2022a. Modular deep learning segmentation algorithm for concrete microscopic images. *Constr. Build. Mater.* 349, 128736. <https://doi.org/10.1016/j.conbuildmat.2022.128736>
- Hilloulin, B., Hafidi, A., Boudache, S., Loukili, A., 2022b. Interpretable Ensemble Machine Learning for the prediction of the expansion of cementitious materials under external sulfate attack. submitted.
- Kovačević, M., Lozančić, S., Nyarko, E.K., Hadzima-Nyarko, M., 2022. Application of Artificial Intelligence Methods for Predicting the Compressive Strength of Self-Compacting Concrete with Class F Fly Ash. *Materials* 15, 4191. <https://doi.org/10.3390/ma15124191>
- Kovler, K., Roussel, N., 2011. Properties of fresh and hardened concrete. *Cem. Concr. Res., Special Issue: 13th International Congress on the Chemistry of Cement* 41, 775–792. <https://doi.org/10.1016/j.cemconres.2011.03.009>
- Li, D., Wang, D., Ren, C., Rui, Y., 2018. Investigation of rheological properties of fresh cement paste containing ultrafine circulating fluidized bed fly ash. *Constr. Build. Mater.* 188, 1007–1013. <https://doi.org/10.1016/j.conbuildmat.2018.07.186>

- Liang, M., Chang, Z., Wan, Z., Gan, Y., Schlangen, E., Šavija, B., 2022. Interpretable Ensemble-Machine-Learning models for predicting creep behavior of concrete. *Cem. Concr. Compos.* 125, 104295. <https://doi.org/10.1016/j.cemconcomp.2021.104295>
- Mandal, R., Panda, S.K., Nayak, S., 2023. Rheology of Concrete: Critical Review, recent Advancements, and future perspectives. *Constr. Build. Mater.* 392, 132007. <https://doi.org/10.1016/j.conbuildmat.2023.132007>
- Neville, A., 2004. The confused world of sulfate attack on concrete. *Cem. Concr. Res.* 34, 1275–1296. <https://doi.org/10.1016/j.cemconres.2004.04.004>
- Slavcheva, G., Artamonova, O., Babenko, D., Ibryaeva, A., 2020. Effect of Limestone Filler Dosage and Granulometry on the 3D printable Mixture Rheology. *IOP Conf. Ser. Mater. Sci. Eng.* 972, 012042. <https://doi.org/10.1088/1757-899X/972/1/012042>
- Sonebi, M., Cevik, A., 2009. Prediction of Fresh and Hardened Properties of Self-Consolidating Concrete Using Neurofuzzy Approach. *J. Mater. Civ. Eng.* 21, 672–679. [https://doi.org/10.1061/\(ASCE\)0899-1561\(2009\)21:11\(672\)](https://doi.org/10.1061/(ASCE)0899-1561(2009)21:11(672))
- Sonebi, M., Lachemi, M., Hossain, K.M.A., 2013. Optimisation of rheological parameters and mechanical properties of superplasticised cement grouts containing metakaolin and viscosity modifying admixture. *Constr. Build. Mater., 25th Anniversary Session for ACI 228 – Building on the Past for the Future of NDT of Concrete* 38, 126–138. <https://doi.org/10.1016/j.conbuildmat.2012.07.102>
- Thomas, B.S., Yang, J., Mo, K.H., Abdalla, J.A., Hawileh, R.A., Ariyachandra, E., 2021. Biomass ashes from agricultural wastes as supplementary cementitious materials or aggregate replacement in cement/geopolymer concrete: A comprehensive review. *J. Build. Eng.* 40, 102332. <https://doi.org/10.1016/j.jobe.2021.102332>
- Yeh, Y., I, C., 2007. Concrete Compressive Strength. UCI Machine Learning Repository. ADEME - Bilans ,2024. URL <https://bilans-ges.ademe.fr/>.
- Karim, Md.R., Zain, M.F.M., Jamil, M., Lai, F.C., Islam, Md.N., 2011. Use of Wastes in Construction Industries as an Energy Saving Approach. *Energy Procedia, The Proceedings of International Conference on Smart Grid and Clean Energy Technologies (ICSGCE 2011 12, 915–919.* <https://doi.org/10.1016/j.egypro.2011.10.120>
- Kovačević, M., Lozančić, S., Nyarko, E.K., Hadzima-Nyarko, M., 2022. Application of Artificial Intelligence Methods for Predicting the Compressive Strength of Self-Compacting Concrete with Class F Fly Ash. *Materials* 15, 4191. <https://doi.org/10.3390/ma15124191>
- Thomas, B.S., Yang, J., Mo, K.H., Abdalla, J.A., Hawileh, R.A., Ariyachandra, E., 2021. Biomass ashes from agricultural wastes as supplementary cementitious materials or aggregate replacement in cement/geopolymer concrete: A comprehensive review. *J. Build. Eng.* 40, 102332. <https://doi.org/10.1016/j.jobe.2021.102332>