

# Modélisation de l'étalement des bétons autoplaçants par apprentissage automatique

**Abdelhamid Hafidi<sup>1,2</sup>, Benoit Hilloulin<sup>1</sup>, Ilhame Harbouz<sup>1</sup>, Louise Lemesre<sup>1,2</sup>, Ahmed Loukili<sup>1,2</sup>**

<sup>1</sup> Nantes Université, Ecole Centrale Nantes, CNRS, GeM, UMR 6183, F-44321 Nantes, France

<sup>2</sup> Edycem, Rue du Fléchet, 85600, Boufféré, France

**RESUME** Le comportement des bétons autoplaçants à l'état frais pour les ciments traditionnels est un phénomène complexe. Avec l'évolution des contraintes écologiques, la fabrication des bétons à faible teneur en clinker est devenue primordiale, ce qui modifie leur comportement rhéologique. Dans cette étude, quatre modèles d'apprentissage automatique ont été utilisés pour classer les bétons en se basant sur les diamètres d'étalement. Les données utilisées comprenaient 1571 observations, principalement des bétons autoplaçants contenant des ajouts tels que le laitier et les cendres volantes. Les modèles ont donné des résultats satisfaisants. Les meilleurs modèles sont « RandomForest » et « XGBoost » obtenant des F1-scores de 65% et 64% respectivement. Eau/Liant et la quantité de gravier sont les facteurs les plus influents sur l'étalement déterminé par l'outil "Shapley Additive Explanations" (SHAP).

**Mots-clefs** béton autoplaçant, intelligence artificielle, étalement, Classification, SHAP

## I. INTRODUCTION

Le ciment est le matériau le plus couramment utilisé dans le monde, mais sa production abondante entraîne de fortes émissions de dioxyde de carbone (Kovačević et al., 2022). L'utilisation des additions minérales permet de réduire considérablement cet impact environnemental, mais entraîne une modification des propriétés rhéologiques du ciment, comme c'est le cas pour le laitier (Boukendakdji et al., 2009), les cendres volantes (Li et al., 2018) ou le filler (Slavcheva et al., 2020). L'étude du comportement à l'état frais des ciments contenant des taux élevés des additions minérales, requiert une bonne compréhension de l'impact de ces additions sur la rhéologie. En effet, les propriétés rhéologiques du béton frais sont liées à l'hydratation du ciment et aux interactions physico-chimiques dans le système de pâte cimentaire (Ferraris and Martys, 2003). Le diamètre de l'étalement est un paramètre rhéologique déterminant dans le cas des bétons autoplaçants. Divers modèles empiriques ont été développés pour évaluer ce paramètre (Xie et al., 2021). Toutefois, ces modèles semblent être approximatifs et ne permettent pas de déterminer la classe de consistance avec une grande précision.

L'utilisation de l'apprentissage automatique est de plus en plus courante dans les études de génie civil, et des applications récentes ont ouvert de nouvelles perspectives de recherche. Par exemple, des approches telles que les réseaux de neurones convolutifs et les arbres de décision ont été couronnées de succès dans l'évaluation des qualités du béton à différentes échelles, allant de l'intégrité structurelle à l'identification à micro-échelle des fissures (Dorafshan et al., 2018 ;

Hilloulin et al., 2022). De même, les modèles d'apprentissage automatique d'ensemble sophistiqués ont récemment montré des résultats prometteurs dans l'interprétation des aspects physiques dans différents cas, tels que le fluage (Liang et al., 2022), le retrait (Hilloulin and Tran, 2022) et la résistance à la compression (Young et al., 2019).

Dans la présente étude, une nouvelle approche basée sur l'intelligence artificielle est adoptée pour classifier les bétons selon leur étalement et déterminer les facteurs les plus influents et leur impact sur le comportement global à l'état frais du béton.

## II. Description de la base de données

### A. Collection de la base de données

Dans cette étude la modélisation et la classification des bétons sont réalisées pour 1571 formulations. Dans la base de données sont collectés les résultats de plus de 104 études tirées de la littérature (Xie et al., 2021; Yang et al., 2021; Yeh, 2007). Parmi les paramètres considérés, on trouve la quantité du ciment et des additions, le dosage en superplastifiant ainsi que le ratio Eau/Liant. Le tableau 1 fournit une description détaillée de la base de données.

**TABLEAU 1.** Description de la base de données

	Moyenne	Ecart-type	min	max
Ciment (kg/m <sup>3</sup> )	354,40	109,19	0	707
Laitier (kg/m <sup>3</sup> )	24,53	63,79	0	600
Fumée de silice (kg/m <sup>3</sup> )	5,02	18,31	0	250
Cendres volantes (kg/m <sup>3</sup> )	56,47	84,78	0	461
Kaolin (kg/m <sup>3</sup> )	6,15	20,55	0	180
Filler (kg/m <sup>3</sup> )	51,16	106,4	0	600
Autres additions (kg/m <sup>3</sup> )	21,74	54,73	0	506
Eau/Liant	0,36	0,10	0,12	0,79
Eau (kg/m <sup>3</sup> )	188,78	39,46	86,83	803
Sable (kg/m <sup>3</sup> )	839,62	116,51	203	1200
Graviers (kg/m <sup>3</sup> )	785,97	160,63	312,1	1171
SP (%)	6,68	4,22	0	30
Etalement (mm)	667	108	200	945

### B. Prétraitement de la base de données

Comme la base de données est issue de différentes études, elle comporte des données manquantes nécessitant un traitement par des méthodes statistiques et physiques. Par exemple, si la valeur de la teneur en liant n'est pas exprimée en kg/m<sup>3</sup>, une conversion est effectuée pour assurer l'homogénéité de la base de données. De plus, afin d'améliorer la précision des modèles, une normalisation et une standardisation des données d'entrée sont réalisées.

### C. Classe de consistance

La classification des bétons est basée sur la norme française NF EN 12350-8, qui distingue trois classes de consistance : SF 1, SF 2 et SF 3. Le tableau 2 indique les diamètres d'étalement pour chaque classe. Dans cette étude, deux classes supplémentaires, SF 0 et SF 4, ont été ajoutées pour modéliser les faibles et grands diamètres d'étalement.

**TABLEAU 2.** Classes d'étalement d'après la norme NF EN 12350-8 incluant les classes supplémentaires SF0 et SF4

Classe	« SF 0 »	SF 1	SF 2	SF 3	« SF 4 »
Etalement (mm)	< 550	550-660	660-750	750-850	> 850

### III. Modèles d'apprentissage automatique

Quatre modèles d'apprentissage automatique, considérés parmi les meilleurs pour résoudre et prédire les phénomènes de génie civil, ont été entraînés sur 80% des formulations et testés sur les autres 20%. Ces modèles ont également été validés à l'aide d'une méthode de validation croisée.

#### A. Forêts d'arbres décisionnels (Random Forest (RF))

Il s'agit d'un algorithme d'apprentissage automatique supervisé largement utilisé dans les problèmes de classification et de régression, combinant les concepts d'agrégation « bootstrap » et de sous-espace aléatoire (Breiman, 2001). Le modèle est composé de nombreux arbres de décision indépendants et chacun des arbres est produit à l'aide d'un processus aléatoire. Premièrement, l'échantillonnage « bootstrap » a été utilisé pour effectuer de nombreux cycles d'échantillonnage. Un sous-ensemble d'entrées est choisi au hasard dans chaque cycle d'échantillonnage, et plusieurs arbres de décision peuvent être entraînés. Enfin, la prévision du modèle RF peut être déterminée en votant ou en faisant la moyenne des résultats des arbres de décision. C'est cette dernière méthode qui a été utilisée dans notre étude.

#### B. « Renforcement du gradient (Gradient Boosting (GB)) »

« Gradient boosting » (GB) intègre un apprenant fort en combinant de nombreux apprenants faibles. Les GB sont d'abord construits pour les problèmes de classification. Après avoir été étendus à la régression par Friedman (2001), la méthode GB considère l'erreur d'arbre précédent après chaque itération et cherche à récupérer l'erreur lors de l'estimation de l'arbre suivant. En conséquence, l'imprécision dans l'ensemble d'arbres suivant diminue régulièrement. De plus, GB est construit sur le concept de « boosting », qui consiste à utiliser plusieurs combinaisons de modèles avec un biais élevé et une faible variance. Les arbres peu profonds sont construits en utilisant les mêmes données que les arbres profonds.

#### C. « XGBoost »

En formant séquentiellement une série d'apprenants faibles, la machine de renforcement de gradient XGBoost utilise une approche d'entraînement pour produire un apprenant fort. Un algorithme d'optimisation de descente de gradient est utilisé à chaque étape pour entraîner un apprenant faible à minimiser la fonction de perte. XGBoost utilise une génération de modèles plus

régularisée pour contrôler le sur apprentissage avec plus de succès. XGBoost est une méthode de GB qui a été améliorée et utilise la dérivée du premier ordre pour l'optimisation. Mais, le XGBoost étend la fonction de perte du second ordre des dérivées de Taylor et utilise à la fois les dérivées du premier et du second ordre.

#### D. « LightGBM (LGBM) »

LGBM est une technique ML récente basée sur des arbres de décision. Microsoft a introduit l'approche LGBM, qui est similaire à XGBoost. Cependant, LGBM ne développe pas d'arborescence au niveau (ligne par ligne/horizontalement), contrairement à la plupart des modèles d'apprentissage automatique basés sur des arbres. Au lieu de cela, il utilise la stratégie de développement des arbres par feuilles, ce qui conduit à un développement vertical. Cela indique qu'il choisit et se développe sur la feuille avec le plus grand potentiel de réduction des pertes. Le coût d'une mauvaise prédiction avait été réduit par cette stratégie de construction. En limitant sa profondeur d'arborescence, LGBM évite également le sur-apprentissage. Le grand nombre d'hyper-paramètres couverts par le LGBM rend son réglage plus difficile, ce qui est le seul inconvénient principal.

## IV. Indicateurs statistiques d'évaluation des modèles

Afin d'évaluer la précision des modèles de classification, trois métriques : précision, rappel et F1-score ont été utilisées. La classification est fondée sur le concept de vrai positif (TP) et faux négatif (FN), qui se produisent lorsqu'une valeur prédite et mesurée sont de même classe. À l'inverse, le faux positif (FP) et le vrai négatif (TN), se produisent lorsque la prédiction et la réalité ne sont pas de même classe. Les équations (1), (2) et (3) sont utilisées pour exprimer ces métriques.

$$Precision = \frac{TP}{TP+FP} \quad (1)$$

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

$$F1\text{-score} = 2 \times \frac{recall \times precision}{recall + precision} \quad (3)$$

## V. Résultats

### A. Performances des modèles

Les résultats des modèles ont été décrits à l'aide de rapports de classification qui contiennent les métriques déjà présentées dans la section IV. Dans cette étude, nous avons présenté uniquement la précision et le F1-score. Le rapport de classification de « sklearn » contient plus d'indicateurs statistiques mais dans cette étude les deux métriques suffisent pour comparer la robustesse des modèles. Le tableau 3 montre les scores de chaque modèle pour les classes d'étalement SF 0 à SF 4. La différence moyenne entre les F1-scores est peu significative. Pour la classe SF 2, le modèle RF est le plus précis avec un F1-score égal à 73% (valeur la plus élevée). Pour la classe SF 0 GB a

obtenu de bons résultats avec un F1-score d'environ 55%. Pour SF 1, XGBoost est le meilleur modèle avec un F1-score de 60%. Dans les quatre cas, tous les modèles montrent des résultats proches, ce qui confirme la grande précision des modèles choisis.

**TABLEAU 3.** Rapport de classification : précision et F1 score des quatre modèles pour les différentes classes d'étalement

Classe	RF		GB		XGBoost		LGBM	
	précision	F1-score	précision	F1-score	précision	F1-score	précision	F1-score
SF 0	47%	45%	55%	54%	50%	50%	52%	46%
SF 1	62%	58%	56%	55%	63%	60%	60%	59%
SF 2	68%	73%	66%	71%	68%	72%	67%	71%
SF 3	70%	57%	56%	41%	59%	53%	65%	55%
SF 4	60%	57%	64%	64%	58%	61%	64%	64%

### B. Matrice de confusion

La matrice de confusion est une technique pour évaluer l'efficacité des modèles, avec deux classes ou plus, représentant les diverses combinaisons de valeurs réelles et prédites. Elle permet de montrer non seulement quelles prévisions étaient bonnes ou mauvaises, mais plus important, quels types d'erreurs ont été commises. Les valeurs prédites de chaque classe sont rapportées dans des colonnes et les valeurs réelles dans des lignes. Le modèle est précis lorsque les valeurs se trouvent sur la diagonale de la matrice. Cela signifie que la classe prédite par le modèle correspond à la classe réelle. La figure 1 montre la matrice de confusion des quatre modèles en utilisant les prédictions de l'ensemble du test. Comme montré dans le tableau 3, tous les modèles utilisés dans la figure 1 ont donné de bons résultats (les valeurs les plus élevées se trouvent sur la diagonale). Le meilleur modèle est RF qui a un F1-score de 65% (moyenne des F1-score). La différence entre les modèles n'est pas significative. La majorité des modèles font des erreurs pour les classes SF 1 et SF 3 et les confondre avec la classe SF 2 (figure 1).

### C. Analyse des paramètres les plus influents

Les paramètres les plus influents sur les prédictions ont été obtenues à l'aide de SHAP, qui est une méthode théorique basée sur le jeu, visant à clarifier la sortie de tout modèle d'apprentissage automatique (Bialek et al., 2022). Cette méthode établit un lien entre l'allocation optimale des crédits et les explications locales. Pour cela, elle utilise les valeurs classiques de « Shapley » issues de la théorie des jeux et leurs extensions associées. La figure 2 présente pour le modèle RF, les « shap value » des cinq classes d'étalement pour les paramètres les plus influents dans la base de données. Ces paramètres sont classés selon l'ordre d'importance pour le modèle RF dans la figure 2. Les paramètres les plus importants sont : le rapport Eau/Liant, la quantité de gravier, la quantité de ciment et le dosage en superplastifiant. La valeur de shap, « shap value », caractérise la contribution de chaque entrée dans la prédiction. Ainsi, une valeur élevée signifie que la contribution de ce paramètre sur la valeur de l'étalement est importante. Dans la figure 2, on peut voir que le rapport Eau/Liant est le plus influent, (shap value de 0,200) suivi par la

quantité du gravier et celle du ciment puis en quatrième place le dosage en superplastifiant (SP) qui est un paramètre très important.

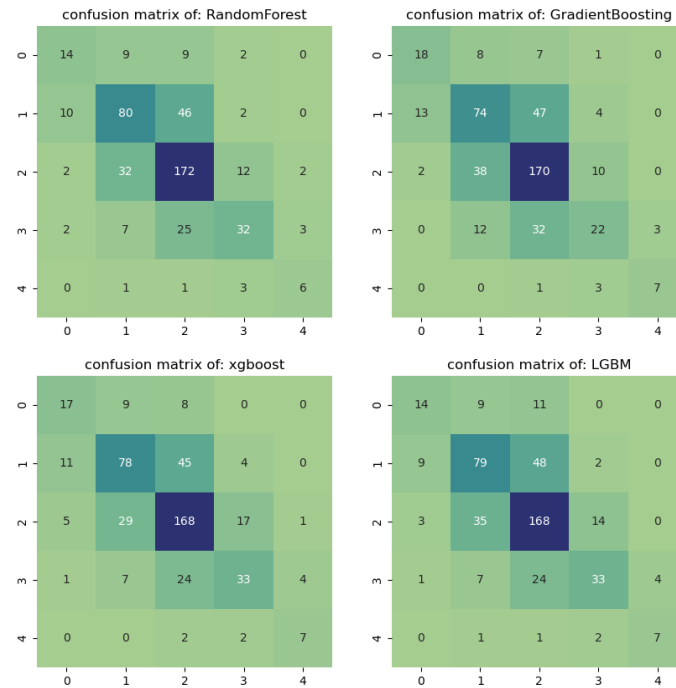


FIGURE 1. Matrices de confusion pour les quatre modèles étudiés (RF, GB, XGBoots et LGBM)




FIGURE 2. Shap value des paramètres étudiés pour le modèle RF en fonction de la classe d'étalement.

## VI. Conclusions

Dans cette étude quatre modèles d'apprentissage automatique ont été utilisés pour prédire la classe de consistance du ciment à partir de la valeur d'étalement. Les quatre algorithmes RF, GB, XGBoost et LGBM ont été entraînés sur une base de données, contenant 1571 spécimens, collectés à partir de la littérature pour prédire les étalements. Les entrées des modèles sont majoritairement les additions minérales et la composition des mélanges. Sur la base des résultats obtenus, les conclusions suivantes peuvent être tirées :

- Tous les modèles ML montrent de bons résultats et la prédiction de la classe de d'étalement du béton a été évaluée avec une précision satisfaisante pour un problème complexe.
- Des résultats comparables peuvent être obtenus avec les modèles d'apprentissage automatique testés, ce qui confirme la cohérence et la précision de ces techniques.
- RF et XGboost ont eu les meilleurs résultats et ont prédit correctement 304/472 et 303/472 spécimens de l'ensemble de test avec une grande précision.
- Le critère de classification est basé sur la norme française NF EN 12350-8 des classes de consistance ce qui permet d'utiliser les modèles entraînés par les industriels.
- La technique SHAP a été utilisée pour analyser l'importance des facteurs pour chaque prédiction et selon cette analyse, le rapport Eau/Liant, les agrégats, le ciment et le superplastifiant sont les facteurs les plus influents.

Même si les problèmes de rhéologie des bétons sont intrinsèquement complexes en raison de la variété des phénomènes qui entrent en jeu, cette étude ouvre une nouvelle voie de recherche pour l'utilisation de techniques d'apprentissage automatique, pour la classification des matériaux cimentaires selon leur comportement rhéologique.

## VII. REFERENCES

- Białek, J., Bujalski, W., Wojdan, K., Guzek, M., Kurek, T., 2022. Dataset level explanation of heat demand forecasting ANN with SHAP. *Energy* 261, 125075. <https://doi.org/10.1016/j.energy.2022.125075>
- 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>
- Dorafshan, S., Thomas, R.J., Maguire, M., 2018. Comparison of deep convolutional neural networks and edge detectors for image-based crack detection in concrete. *Constr. Build. Mater.* 186, 1031–1045. <https://doi.org/10.1016/j.conbuildmat.2018.08.011>
- Ferraris, C.F., Martys, N.S., 2003. Relating fresh concrete viscosity measurements from different rheometers. *J. Res. Natl. Inst. Stand. Technol.* 108, 229. <https://doi.org/10.6028/jres.108.021>
- Friedman, J.H., 2001. Greedy function approximation: A gradient boosting machine. *Ann. Stat.* 29. <https://doi.org/10.1214/aos/1013203451>

- Hilloulin, B., Bekrine, I., Schmitt, E., Loukili, A., 2022. 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., Tran, V.Q., 2022. Using machine learning techniques for predicting autogenous shrinkage of concrete incorporating superabsorbent polymers and supplementary cementitious materials. *J. Build. Eng.* 49, 104086. <https://doi.org/10.1016/j.jobbe.2022.104086>
- 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>
- 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>
- 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>
- Xie, T., Mohamad Ali, M.S., Elchalakani, M., Visintin, P., 2021. Modelling fresh and hardened properties of self-compacting concrete containing supplementary cementitious materials using reactive moduli. *Constr. Build. Mater.* 272, 121954. <https://doi.org/10.1016/j.conbuildmat.2020.121954>
- Yang, L., An, X., Du, S., 2021. Estimating workability of concrete with different strength grades based on deep learning. *Measurement* 186, 110073. <https://doi.org/10.1016/j.measurement.2021.110073>
- Yeh, I.-C., 2007. Modeling slump flow of concrete using second-order regressions and artificial neural networks. *Cem. Concr. Compos.* 29, 474–480. <https://doi.org/10.1016/j.cemconcomp.2007.02.001>
- Young, B.A., Hall, A., Pilon, L., Gupta, P., Sant, G., 2019. Can the compressive strength of concrete be estimated from knowledge of the mixture proportions?: New insights from statistical analysis and machine learning methods. *Cem. Concr. Res.* 115, 379–388. <https://doi.org/10.1016/j.cemconres.2018.09.006>