



الجمهورية الجزائرية الديمقراطية الشعبية

République algérienne démocratique et populaire

وزارة التعليم العالي والبحث العلمي

Ministère de l'enseignement supérieur et de la recherche  
scientifique



جامعة عين تموشنت بلحاج بوشعيب

Université d'Ain-Temouchent - Belhadj Bouchaib

Faculté des Sciences et de la Technologie

Département de Génie Civil & Travaux Publics

Mémoire pour l'Obtention du diplôme de Master

Filière : GÉNIE CIVIL

Spécialité : MATÉRIAUX

Thème :

Prédiction des propriétés à l'état durci du béton  
léger à l'aide de l'intelligence artificielle

PRESENTE PAR :

BACHIR RAYANE ABDELAZIZ

HADJOUTI SAID

SOUTENU LE 23/06/2026

DEVANT LE JURY COMPOSE DE :

PRESIDENT : KADDOUR Hakim

EXAMINATEUR : DERBAL Rachid

ENCADREUR : DOUNANE Nawal

ANNEE UNIVERSITAIRE 2025/2026



## *Dédicace*

Je dédie ce modeste travail :

À ma chère mère, qui a toujours été un grand soutien moral par son dévouement et ses encouragements constants pour mon bien-être et mon bonheur, en témoignage de ma profonde reconnaissance.

À mon cher père, qui s'est consacré avec amour et courage à notre éducation, afin qu'il puisse jouir du fruit de ses sacrifices , il a toujours été pour moi un père exceptionnel et je n'ai rien de plus cher à lui offrir que ce travail en signe de ma gratitude et de mon respect.

À ma chère sœur, le battement de mon cœur et ma compagne de route qui remplit ma vie de chaleur et d'affection, et à mon cher frère, mon précieux soutien dont je suis fier, qui a partagé mon enfance et mes pas, et qui a toujours été une aide face aux difficultés , à vous deux, tout mon amour et ma considération.

À mon cher ami "Said", ce frère que ma mère n'a pas mis au monde et ce compagnon de route qui ne m'a jamais épargné ses conseils et son aide tout au long de la réalisation de cette recherche, se révélant être un ami fidèle en toutes circonstances.

*Rayane Abdelaziz*



## *Dédicace*

Je dédie ce modeste travail :

À mes chers parents, pour leur soutien constant, leurs sacrifices inestimables et leurs encouragements permanents qui ont éclairé mon chemin. Aucun mot ne saurait exprimer ma profonde gratitude et mon amour éternel

À ma chère famille, mes proches, ainsi qu'à mes précieux amis et collègues qui m'ont accompagné, soutenu et encouragé tout au long de ce parcours académique.

À mon cher ami et collègue "Bachir rayane " qui a été un véritable pilier tout au long de la préparation de ce mémoire. Grâce à sa présence, son aide précieuse et ses encouragements, j'ai pu surmonter de nombreuses difficultés. À toi, mon cher ami, je dédie ce succès en signe de reconnaissance.

*Said*

# Remerciements

Nous tenons à exprimer notre profonde gratitude à notre enseignante encadrante, **Dounane Nawal**, pour avoir accepté de superviser ce mémoire, ainsi que pour ses directives éclairées, ses remarques pertinentes et ses précieux conseils tout au long de ce travail.

Nos vifs remerciements s'adressent également aux honorables membres du jury. Nous remercions tout particulièrement le Président du jury pour avoir accepté de présider cette soutenance et pour le temps qu'il y a consacré, ainsi que l'Examineur pour avoir accepté d'examiner ce travail et pour l'attention et le soin accordés lors de sa lecture et de son évaluation.

Nous adressons aussi nos sincères remerciements à l'ensemble des enseignants du Département de Génie Civil et Travaux Publics de la Faculté des Sciences et de la Technologie de l'Université Belhadj Bouchaïb d'Ain Témouchent, qui ont contribué à notre formation, ainsi qu'à tout le personnel de la bibliothèque pour leur disponibilité et leur aide précieuse. Que Dieu les récompense de la meilleure des façons.

Enfin, nous remercions chaleureusement toute personne qui nous a apporté son aide ou son soutien, de près ou de loin, tout au long de la réalisation de ce travail. Nous prions Dieu Tout-Puissant d'inscrire cela parmi leurs bonnes œuvres.

# Résumé

Le béton léger s'impose progressivement dans le domaine du génie civil grâce à ses nombreux avantages, notamment la réduction du poids propre des structures et l'amélioration de l'isolation thermique. Toutefois, la complexité de sa composition rend les méthodes expérimentales conventionnelles moins efficaces. En effet, ces dernières présentent plusieurs limitations, telles qu'un coût élevé, des délais d'exécution importants et l'impossibilité d'explorer l'ensemble des formulations potentielles.

Dans ce contexte, cette étude développe et compare quatre modèles d'apprentissage automatique : les réseaux de neurones artificiels (RNN), Random Forest (RF), les machines à vecteurs de support (SVM) et XGBoost. L'objectif est de prédire simultanément quatre propriétés essentielles du béton léger : la résistance à la compression (RC), la résistance à la traction (RT), la masse volumique sèche (MVS) et le module d'élasticité (ME). La base de données utilisée a été constituée à partir de la littérature scientifique internationale et comprend douze variables d'entrée.

Les résultats obtenus mettent en évidence la supériorité du modèle XGBoost, qui atteint un coefficient de détermination de  $R^2 = 0.97$  pour la prédiction de la résistance à la compression et de la masse volumique sèche. Le modèle Random Forest s'est distingué dans la prédiction de la résistance à la traction avec un  $R^2 = 0.97$ . À l'inverse, le modèle SVM a présenté les performances les plus modestes, avec un coefficient de détermination moyen de  $R^2 = 0.84$ .

La comparaison des résultats avec ceux rapportés dans la littérature confirme que les modèles d'apprentissage automatique étudiés surpassent les approches traditionnelles de prédiction. Ces outils offrent ainsi des perspectives prometteuses pour l'optimisation et la conception de nouvelles formulations de béton léger.

**Mots-clés :** béton léger, apprentissage automatique, RNN, Random Forest, SVM, XGBoost, résistance à la compression, résistance à la traction, module d'élasticité, masse volumique sèche.

## ملخص

يفرض الخرسانة الخفيفة نفسها تدريجياً في مجال الهندسة المدنية بفضل مزاياها العديدة، وعلى رأسها تقليل الوزن الذاتي للمنشآت وتحسين العزل الحراري. غير أن تعقيد تركيبها يجعل الطرق التجريبية التقليدية أقل فعالية. إذ تعاني هذه الطرق من عدة قيود، من بينها ارتفاع التكلفة، وطول مدة الإنجاز، وصعوبة استكشاف جميع التركيبات الممكنة للخرسانة.

في هذا السياق، تهدف هذه الدراسة إلى تطوير ومقارنة أربعة نماذج من التعلم الآلي، وهي: الشبكات العصبية الاصطناعية (ANN)، وغابات القرار العشوائية (Random Forest)، وآلات المتجهات الداعمة (SVM)، ونموذج XGBoost. ويمثل الهدف الرئيسي في التنبؤ المتزامن بأربع خصائص أساسية للخرسانة الخفيفة، وهي: مقاومة الضغط، ومقاومة الشد، والكثافة الجافة، ومعامل المرونة. وقد تم بناء قاعدة البيانات المستخدمة انطلاقاً من الأدبيات العلمية الدولية، وتضم اثني عشر متغيراً مدخلاً.

أظهرت النتائج تفوق نموذج XGBoost حيث حقق معامل تحديد بلغ  $R^2 = 0.97$  في التنبؤ بكل من مقاومة الضغط والكثافة الجافة. كما تميز نموذج Forest Random في التنبؤ بمقاومة الشد، محققاً قيمة  $R^2 = 0.97$ . في المقابل سجل نموذج SVM أضعف أداء بين النماذج المدروسة، بمتوسط معامل تحديد قدره  $R^2 = 0.84$ .

وتؤكد مقارنة النتائج مع ما ورد في الأدبيات العلمية أن نماذج التعلم الآلي المدروسة تتفوق على الأساليب التقليدية للتنبؤ. ومن ثم، توفر هذه النماذج آفاقاً واعدة لتحسين وتصميم تركيبات جديدة للخرسانة الخفيفة بكفاءة ودقة أكبر.

**الكلمات المفتاحية:** الخرسانة الخفيفة، التعلم الآلي، الشبكات العصبية الاصطناعية (RNN)، غابات القرار العشوائية (Random Forest)، آلات المتجهات الداعمة (SVM)، XGBoost، مقاومة الضغط، مقاومة الشد، معامل المرونة، الكثافة الجافة.

# Abstract

Lightweight concrete has increasingly gained importance in civil engineering due to its numerous advantages, particularly the reduction of structural self-weight and the improvement of thermal insulation. However, its complex composition limits the effectiveness of conventional experimental methods. These methods face several constraints, including high costs, long testing durations, and the inability to explore all possible concrete formulations.

In this context, this study develops and compares four machine learning models : Artificial Neural Networks (ANN), Random Forest (RF), Support Vector Machines (SVM), and XGBoost. The main objective is to simultaneously predict four key properties of lightweight concrete : compressive strength (CS), tensile strength (TS), dry density (DD), and modulus of elasticity (MOE). The dataset was compiled from international scientific literature and includes twelve input variables.

The results highlight the superior performance of the XGBoost model, which achieved a coefficient of determination of  $R^2 = 0.97$  for predicting both compressive strength and dry density. The Random Forest model demonstrated the best performance for tensile strength prediction, with an  $R^2 = 0.97$ . In contrast, the SVM model exhibited the lowest performance among the studied models, with an average  $R^2$  value of 0.84.

A comparison with findings reported in the literature confirms that the machine learning models investigated outperform traditional prediction approaches. Therefore, these models offer promising opportunities for the optimization and design of new lightweight concrete mixtures with greater efficiency and accuracy.

**Keywords :** Lightweight concrete, Machine Learning, Artificial Neural Networks (ANN), Random Forest, Support Vector Machines (SVM), XGBoost, Compressive Strength, Tensile Strength, Modulus of Elasticity, Dry Density.

# Table des matières

|                                                                                  |          |
|----------------------------------------------------------------------------------|----------|
| Table des figures                                                                | XI       |
| Liste des tableaux                                                               | XII      |
| Code Listings                                                                    | XIII     |
| Abréviations                                                                     | 1        |
| Introduction générale                                                            | 2        |
| <b>I Partie Théorique</b>                                                        | <b>4</b> |
| <b>1 Revue bibliographique sur les bétons légers</b>                             | <b>5</b> |
| 1.1 Généralités sur les bétons légers :                                          | 5        |
| 1.1.1 Définition et concepts fondamentaux :                                      | 5        |
| 1.1.2 Historique :                                                               | 6        |
| 1.1.3 Classification normative des bétons légers et caractéristiques associées : | 7        |
| 1.2 Constituants et méthodes de formulation des bétons légers :                  | 7        |
| 1.2.1 Liants hydrauliques et additions minéraux :                                | 8        |
| 1.2.2 Granulats légers :                                                         | 9        |
| 1.2.2.1 Granulats légers naturels :                                              | 10       |
| 1.2.2.2 Granulats légers artificiels :                                           | 11       |
| 1.2.2.3 Granulats légers recyclés :                                              | 13       |
| 1.2.3 Adjuvants :                                                                | 14       |
| 1.2.4 Eau de gâchage :                                                           | 14       |
| 1.3 Types de bétons légers :                                                     | 15       |
| 1.3.1 Béton à granulats légers :                                                 | 15       |
| 1.3.2 Béton cellulaire :                                                         | 16       |
| 1.3.3 Béton caverneux (béton sans fines) :                                       | 16       |
| 1.4 Propriétés des bétons légers :                                               | 17       |
| 1.4.1 Propriétés physiques :                                                     | 17       |
| 1.4.1.1 masse volumique :                                                        | 17       |
| 1.4.1.2 Porosité :                                                               | 18       |
| 1.4.2 Propriétés mécaniques :                                                    | 19       |
| 1.4.2.1 Résistance à la compression :                                            | 19       |
| 1.4.2.2 Résistance à la traction :                                               | 19       |
| 1.4.2.3 Module d'élasticité :                                                    | 20       |
| 1.4.3 Propriétés thermiques :                                                    | 20       |
| 1.4.4 Propriétés acoustiques :                                                   | 21       |

|           |                                                                                                    |           |
|-----------|----------------------------------------------------------------------------------------------------|-----------|
| 1.4.5     | Durabilité :                                                                                       | 21        |
| 1.5       | Avantages et limites des bétons légers :                                                           | 21        |
| 1.5.1     | Avantages du béton léger :                                                                         | 21        |
| 1.5.2     | Inconvénients :                                                                                    | 22        |
| 1.6       | Applications des bétons légers en génie civil :                                                    | 23        |
| 1.6.1     | Bâtiments et éléments structuraux :                                                                | 23        |
| 1.6.2     | Ponts et ouvrages d'art :                                                                          | 23        |
| 1.6.3     | Isolation et réhabilitation :                                                                      | 23        |
| 1.7       | Synthèse critique des travaux antérieurs :                                                         | 23        |
| 1.7.1     | Résultats expérimentaux majeurs :                                                                  | 24        |
| 1.7.2     | Besoin d'outils prédictifs :                                                                       | 24        |
| 1.8       | Conclusion :                                                                                       | 24        |
| <b>2</b>  | <b>Fondements théoriques de l'apprentissage automatique et des réseaux de neurones artificiels</b> | <b>25</b> |
| 2.1       | Intelligence Artificielle :                                                                        | 25        |
| 2.1.1     | Définition :                                                                                       | 25        |
| 2.1.2     | Historique :                                                                                       | 26        |
| 2.1.3     | Importance de l'intelligence artificielle en génie civil :                                         | 27        |
| 2.2       | Machine Learning :                                                                                 | 27        |
| 2.2.1     | Machine Learning : historique et définition :                                                      | 27        |
| 2.2.2     | Différence entre ML et programmation classique :                                                   | 28        |
| 2.2.3     | Types d'apprentissage                                                                              | 29        |
| 2.3       | Algorithmes de régression en Machine Learning                                                      | 30        |
| 2.3.1     | Analyse de régression :                                                                            | 30        |
| 2.3.2     | Machine à vecteurs de support (Support vector machine (SVM)) :                                     | 31        |
| 2.3.3     | Random Forest (Forêt aléatoire)                                                                    | 32        |
| 2.3.4     | XGBoost (Extreme Gradient Boosting)                                                                | 33        |
| 2.4       | Deep Learning :                                                                                    | 34        |
| 2.4.1     | Applications en génie civil :                                                                      | 35        |
| 2.4.2     | Réseaux de Neurones Artificiels :                                                                  | 35        |
| 2.4.2.1   | Architecture des réseaux de neurones artificiels :                                                 | 36        |
| 2.4.2.2   | Fonctions d'activation :                                                                           | 37        |
| 2.4.2.3   | Apprentissage d'un réseau de neurones artificiels :                                                | 39        |
| 2.5       | Conclusion                                                                                         | 40        |
| <b>II</b> | <b>Partie Pratique</b>                                                                             | <b>41</b> |
| <b>3</b>  | <b>Méthodologie et mise en œuvre des modèles d'apprentissage automatique</b>                       | <b>42</b> |
| 3.1       | Travaux récents sur l'utilisation de l'IA pour les bétons légers :                                 | 43        |
| 3.2       | Description de la base de données :                                                                | 44        |
| 3.3       | Analyse exploratoire des données :                                                                 | 46        |
| 3.3.1     | Statistiques descriptives :                                                                        | 46        |
| 3.3.2     | Analyse des corrélations entre variables :                                                         | 46        |
| 3.4       | Prétraitement des données :                                                                        | 47        |
| 3.5       | Modèles d'apprentissage automatique utilisés :                                                     | 48        |
| 3.5.1     | Réseaux neuronaux artificiels (RNA) :                                                              | 48        |

|          |                                                                                          |           |
|----------|------------------------------------------------------------------------------------------|-----------|
| 3.5.2    | Forêt Aléatoire (Random Forest) :                                                        | 49        |
| 3.5.3    | XGBoost (Gradient Boosting) :                                                            | 49        |
| 3.5.4    | Machine à vecteurs de support (SVM) :                                                    | 50        |
| 3.6      | Métriques statistiques d'évaluation des modèles dévelop :                                | 50        |
| 3.7      | Conclusion :                                                                             | 51        |
| <b>4</b> | <b>Résultats et Analyse des Modèles de Prédiction</b>                                    | <b>52</b> |
| 4.1      | Analyse descriptive des données :                                                        | 52        |
| 4.1.1    | Distribution des variables d'entrée et des propriétés cibles :                           | 52        |
| 4.1.2    | Corrélations entre les variables :                                                       | 55        |
| 4.2      | Résultats et interprétation du modèle SVM :                                              | 57        |
| 4.2.1    | Performance sur l'ensemble de test :                                                     | 58        |
| 4.3      | Résultats et interprétation du modèle ANN :                                              | 59        |
| 4.3.1    | Performance sur l'ensemble de test :                                                     | 59        |
| 4.4      | Résultats et interprétation du modèle Random Forest :                                    | 60        |
| 4.4.1    | Performance et analyse des erreurs                                                       | 60        |
| 4.5      | Résultats et interprétation du modèle XGBoost :                                          | 61        |
| 4.6      | Comparaison globale des modèles :                                                        | 62        |
| 4.6.1    | Discussion sur le meilleur modèle pour chaque propriété :                                | 63        |
| 4.6.2    | Analyse des écarts et recommandations pour la pratique :                                 | 63        |
| 4.7      | Comparaison des performances des modèles développés avec les travaux de la littérature : | 64        |
| 4.8      | Présentation de l'application web :                                                      | 66        |
| 4.8.1    | Principe de fonctionnement de l'application web :                                        | 66        |
| 4.8.2    | Résultats obtenus via l'application Concrete AI :                                        | 67        |
| 4.9      | Conclusion :                                                                             | 68        |
|          | <b>Conclusion générale</b>                                                               | <b>69</b> |
|          | <b>Perspectives et recommandations</b>                                                   | <b>70</b> |
|          | <b>Bibliographie</b>                                                                     | <b>76</b> |
|          | <b>A Code Listings</b>                                                                   | <b>77</b> |

# Table des figures

|      |                                                                                                                                                        |    |
|------|--------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 1.1  | Différents types de bétons légers [2]                                                                                                                  | 6  |
| 1.2  | colisée de Rome                                                                                                                                        | 7  |
| 1.3  | Panthéon de Rome                                                                                                                                       | 7  |
| 1.4  | Cendres volantes [7]                                                                                                                                   | 8  |
| 1.5  | Fumée de silice [8]                                                                                                                                    | 8  |
| 1.6  | Laitier de haut fourneau (GGBS) [9]                                                                                                                    | 9  |
| 1.7  | Métakaolin [10]                                                                                                                                        | 9  |
| 1.8  | Pierre ponce                                                                                                                                           | 10 |
| 1.9  | Pouzzolane                                                                                                                                             | 11 |
| 1.10 | Schiste expansé                                                                                                                                        | 12 |
| 1.11 | Billes de polystyrène expansé                                                                                                                          | 12 |
| 1.12 | Types de bétons légers [12]                                                                                                                            | 15 |
| 1.13 | Différents types de béton caverneux [5]                                                                                                                | 17 |
| 1.14 | Masse volumique sèche de bétons légers confectionnés avec différents granulats légers à 28 jours [1]                                                   | 18 |
| 1.15 | Porosité du béton [15]                                                                                                                                 | 19 |
| 1.16 | Relation entre la résistance à la compression à 28 jours et la masse volumique du béton frais pour des mélanges à granulats légers [16]                | 19 |
| 1.17 | Valeurs du module d'élasticité de bétons légers à 28 jours issues de différentes études [12]                                                           | 20 |
| 1.18 | Courbes contrainte-déformation de bétons légers à base d'argile expansée : (A) granulats fins et grossiers légers ; (B) granulats fins ordinaires [19] | 22 |
| 2.1  | Schéma de fonctionnement de base de l'apprentissage automatique                                                                                        | 28 |
| 2.2  | Schéma illustratif du processus d'apprentissage supervisé                                                                                              | 30 |
| 2.3  | Schéma illustratif du processus d'apprentissage supervisé                                                                                              | 30 |
| 2.4  | Classificateur à machines à vecteurs de support (SVM) [31]                                                                                             | 32 |
| 2.5  | Transfert des données vers un espace de dimension supérieure dans la machine à vecteurs de support (SVM [31]                                           | 32 |
| 2.6  | Schéma du fonctionnement de l'algorithme Random Forest                                                                                                 | 33 |
| 2.7  | Schéma de fonctionnement de l'algorithme XGBoost                                                                                                       | 34 |
| 2.8  | Intelligence artificielle : du Machine Learning au Deep Learning [34].                                                                                 | 34 |
| 2.9  | Architecture des réseaux de neurones artificiels                                                                                                       | 37 |
| 2.10 | Courbe de la fonction d'activation ReLU (Rectified Linear Unit) [35]                                                                                   | 37 |
| 2.11 | Courbe de la fonction d'activation sigmoïde [35]                                                                                                       | 38 |
| 2.12 | Courbe de la fonction d'activation Tangente Hyperbolique (Tanh) [35]                                                                                   | 39 |
| 2.13 | Principe de fonctionnement d'une fonction d'activation                                                                                                 | 39 |
| 3.1  | Organigramme de la méthodologie de recherche pour la prédiction des propriétés du béton léger.                                                         | 43 |

|      |                                                                                                                                      |    |
|------|--------------------------------------------------------------------------------------------------------------------------------------|----|
| 4.1  | Matrice de corrélation entre les variables d'entrée et la propriété cible 'Masse volumique du béton (MVB) . . . . .                  | 56 |
| 4.2  | Matrice de corrélation entre les variables d'entrée et la propriété cible — Module d'élasticité (ME) . . . . .                       | 56 |
| 4.3  | Matrice de corrélation entre les variables d'entrée et la propriété cible ' Résistance à la compression (RC) . . . . .               | 57 |
| 4.4  | Matrice de corrélation entre les variables d'entrée et la propriété cible 'Résistance à la traction (RT) . . . . .                   | 57 |
| 4.5  | Performances du modèle SVM pour la prédiction de la masse volumique du béton (MVB)                                                   | 58 |
| 4.6  | Performances du modèle SVM pour la prédiction du module d'élasticité (ME) . . . . .                                                  | 58 |
| 4.7  | Performances du modèle SVM pour la prédiction de la résistance à la compression . . . . .                                            | 58 |
| 4.8  | Performances du modèle SVM pour la prédiction de la résistance à la traction . . . . .                                               | 58 |
| 4.9  | Performances du modèle ANN (MVB) . . . . .                                                                                           | 59 |
| 4.10 | Performances du modèle ANN (ME) . . . . .                                                                                            | 59 |
| 4.11 | Performances du modèle ANN (RC) . . . . .                                                                                            | 59 |
| 4.12 | Performances du modèle ANN (RT) . . . . .                                                                                            | 59 |
| 4.13 | Performances du modèle Random Forest pour la prédiction de la masse volumique du béton (MVB) . . . . .                               | 60 |
| 4.14 | Performances du modèle Random Forest pour la prédiction du module d'élasticité (ME) .                                                | 60 |
| 4.15 | Performances du modèle Random Forest pour la prédiction de la résistance à la compression (RC) . . . . .                             | 60 |
| 4.16 | Performances du modèle Random Forest pour la prédiction de la résistance à la traction (RT) . . . . .                                | 60 |
| 4.17 | Performances du modèle XGBoost pour la prédiction de la masse volumique du béton (MVB)                                               | 61 |
| 4.18 | Performances du modèle XGBoost pour la prédiction du module d'élasticité (ME) . . . . .                                              | 61 |
| 4.19 | Performances du modèle XGBoost pour la prédiction de la résistance à la compression (RC)                                             | 62 |
| 4.20 | Performances du modèle XGBoost pour la prédiction de la résistance à la traction (RT) .                                              | 62 |
| 4.21 | Interface d'accueil du site web Concrete AI . . . . .                                                                                | 66 |
| 4.22 | Interface de téléchargement des données via fichier CSV . . . . .                                                                    | 67 |
| 4.23 | Évaluation comparative des performances des modèles d'intelligence artificielle implémentés dans l'application Concrete AI . . . . . | 68 |

# Liste des tableaux

|     |                                                                                                                               |    |
|-----|-------------------------------------------------------------------------------------------------------------------------------|----|
| 1.1 | Comparaison des propriétés physiques et mécaniques entre le béton léger et le béton ordinaire [1]. . . . .                    | 6  |
| 1.2 | Classification des bétons légers en fonction de la masse volumique [4] . . . . .                                              | 7  |
| 1.3 | Propriétés du béton léger confectionné à partir de pierre ponce [5]. . . . .                                                  | 10 |
| 1.4 | Propriétés du béton léger confectionné à partir d'argile expansée [5]. . . . .                                                | 11 |
| 1.5 | Propriétés du béton léger confectionné à partir de schiste expansé [5]. . . . .                                               | 12 |
| 1.6 | Propriétés du béton léger confectionné à partir de billes de polystyrène [5]. . . . .                                         | 13 |
| 1.7 | Récapitulatif des granulats sélectionnés pour la formulation du béton léger [5]. . . . .                                      | 13 |
| 1.8 | Propriétés mécaniques et thermiques des bétons cellulaires en fonction de la masse volumique [5]. . . . .                     | 16 |
| 1.9 | Coefficient de conductivité thermique $\lambda$ en fonction de la masse volumique sèche [4]. . . . .                          | 21 |
| 2.1 | Analyse comparative entre la programmation classique et le machine learning . . . . .                                         | 29 |
| 2.2 | Principaux modèles de régression en machine learning [28, 29]. . . . .                                                        | 31 |
| 3.1 | Synthèse des travaux récents sur l'application du machine learning à la prédiction des propriétés des bétons légers . . . . . | 43 |
| 3.2 | Description des quatre bases de données utilisées . . . . .                                                                   | 45 |
| 3.3 | Récapitulatif des échantillons avant et après prétraitement pour chaque base de données . . . . .                             | 48 |
| 4.1 | Caractéristiques statistiques des variables d'entrée et de la propriété cible 'MVB' . . . . .                                 | 53 |
| 4.2 | Caractéristiques statistiques des variables d'entrée et de la propriété cible 'Module d'élasticité (ME)' . . . . .            | 54 |
| 4.3 | Caractéristiques statistiques des variables d'entrée et de la propriété cible 'Résistance à la compression (RC)' . . . . .    | 54 |
| 4.4 | Caractéristiques statistiques des variables d'entrée et de la propriété cible 'Résistance à la traction (RT)' . . . . .       | 55 |
| 4.5 | Comparaison globale des performances des modèles d'apprentissage automatique . . . . .                                        | 62 |
| 4.6 | Récapitulatif des $R^2$ sur l'ensemble de test . . . . .                                                                      | 63 |
| 4.7 | Comparaison des performances des modèles développés avec les travaux de la littérature . . . . .                              | 65 |

# Code Listings

|                                                                                                                                                                               |    |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| A.1 Code listing du RNA - Masse volumique (importation des bibliothèques, division de la base de données et architecture du réseau de neurones) . . . . .                     | 77 |
| A.2 Code listing du RNA - RC et ME (importation des bibliothèques, division de la base de données, normalisation des données et architecture du réseau de neurones) . . . . . | 78 |
| A.3 Code listing du RNA - RT (importation des bibliothèques, division de la base de données, normalisation des données et architecture du réseau de neurones) . . . . .       | 79 |
| A.4 Code listing du RNA - Compilation du modèle . . . . .                                                                                                                     | 79 |
| A.5 Code listing du SVM - (importation des bibliothèques, division de la base de données et architecture du modèle SVM) . . . . .                                             | 80 |
| A.6 Code listing du Random Forest - (importation des bibliothèques, division de la base de données et architecture du modèle Random Forest) . . . . .                         | 81 |
| A.7 Code listing du XGBoost- (importation des bibliothèques, division de la base de données et architecture du modèle XGBoost) . . . . .                                      | 81 |

# Abréviations

|                      |                                   |
|----------------------|-----------------------------------|
| <b>ANN</b>           | : Réseau de Nneurones Artificiels |
| <b>BL</b>            | : Béton Légers                    |
| <b>DL</b>            | : Deep Learning                   |
| <b>E/L</b>           | : Rapport Eau/Liant               |
| <b>EAM</b>           | : Erreur Absolue Moyenne          |
| <b>IA</b>            | : Intelligence Artificielle       |
| <b>MAE</b>           | : Mean Absolute Error             |
| <b>ME</b>            | : Module d'Élasticité             |
| <b>ML</b>            | : Machine Learning                |
| <b>MVB</b>           | : Masse Volumique du Béton        |
| <b>R<sup>2</sup></b> | : Coefficient de Détermination    |
| <b>RC</b>            | : Résistance à la Compression     |
| <b>RF</b>            | : Random Forest                   |
| <b>RMSE</b>          | : Root Mean Square Error          |
| <b>RT</b>            | : Résistance à la Traction        |
| <b>SVM</b>           | : Support Vector Machine          |
| <b>XGBoost</b>       | : EXtreme Gradient Boosting       |

# Introduction générale

LE béton léger constitue l'une des solutions innovantes de l'ingénierie civile moderne, reconnu pour ses propriétés distinctives en matière de réduction du poids propre des structures et d'amélioration de l'isolation thermique. Cependant, la prédiction précise de ses caractéristiques mécaniques et physiques, telles que la résistance à la compression, la résistance à la traction et la masse volumique, représente un défi majeur, compte tenu de la complexité de sa composition et de la multiplicité des facteurs influents. Traditionnellement, ce processus repose sur des essais en laboratoire coûteux et chronophages, qui ne permettent pas une exploration systématique de l'ensemble des formulations possibles [1]

Face à ces limitations, l'intégration des techniques de l'intelligence artificielle, notamment l'apprentissage automatique et l'apprentissage profond, offre une alternative prometteuse pour développer des modèles prédictifs précis et fiables, basés sur l'exploitation des données expérimentales issues de la littérature scientifique. Cette approche contribue à l'amélioration de la qualité de production et à la réduction significative des coûts de conception.

La problématique de ce travail se formule ainsi : dans quelle mesure les modèles d'apprentissage automatique, tels que les réseaux de neurones artificiels (ANN), la forêt aléatoire (Random Forest), la machine à vecteurs de support (SVM) et le XGBoost, peuvent-ils surpasser les méthodes expérimentales et empiriques traditionnelles pour modéliser les relations complexes entre les paramètres de composition du béton léger et ses propriétés à l'état durci ? et comment exploiter les données massives issues des travaux antérieurs pour construire un outil numérique capable de prédire ces propriétés avant la phase de fabrication ?

Ce travail vise principalement à évaluer l'efficacité des algorithmes d'apprentissage automatique pour la prédiction des propriétés mécaniques et physiques du béton léger à l'état durci. Les objectifs spécifiques se déclinent comme suit :

- Constituer une base de données exhaustive et représentative à partir de la littérature scientifique internationale, regroupant les paramètres de composition et les propriétés du béton léger.
- Développer et comparer les performances de quatre modèles prédictifs : les réseaux de neurones artificiels (ANN), la forêt aléatoire (Random Forest), la machine à vecteurs de support (SVM) et le XGBoost.
- Identifier l'algorithme le plus précis et le plus fiable pour modéliser les relations complexes entre les paramètres du mélange et les propriétés cibles.

Afin d'atteindre ces objectifs, le travail est organisé en quatre chapitres :

- **Chapitre 1** : consacré à la revue bibliographique sur le béton léger, couvrant ses types, ses constituants, ainsi que ses propriétés physiques et mécaniques à l'état frais et durci.
- **Chapitre 2** : présente les fondements théoriques de l'intelligence artificielle, en mettant l'accent sur les principes de l'apprentissage automatique, de l'apprentissage profond et des algorithmes de prédiction retenus dans ce travail.

- **Chapitre 3** : expose la méthodologie adoptée, depuis la collecte et le prétraitement des données jusqu'à la conception et la structuration des modèles prédictifs.
- **Chapitre 4** : est consacré à la présentation et à l'analyse des résultats, où les performances des modèles sont évaluées et comparées à l'aide de métriques statistiques standardisées, afin d'identifier le modèle optimal pour chaque propriété cible.

Première partie

Partie Théorique

# Chapitre 1

## Revue bibliographique sur les bétons légers

Ce secteur de la construction a connu une mutation profonde, passant progressivement de l'usage des matériaux locaux traditionnels à l'adoption de solutions industrielles innovantes telles que l'acier, le béton et les matériaux composites, ouvrant ainsi de larges perspectives techniques et architecturales. Face à l'intensification des défis environnementaux et économiques actuels, il est devenu impératif pour les acteurs du domaine de développer des matériaux de construction durables, capables de réduire l'impact environnemental et la consommation énergétique, tout en garantissant des performances structurelles élevées [1].

Dans ce contexte, le béton léger s'est imposé comme une alternative technique majeure au béton conventionnel. Il est défini normativement, selon les instances RILEM (Réunion Internationale des Laboratoires et Experts des Matériaux) et ACI (American Concrete Institute), par une masse volumique apparente sèche ne dépassant pas  $1800 \text{ kg/m}^3$ . Cette technologie repose principalement sur l'incorporation de granulats légers, tels que l'argile expansée, permettant de réduire significativement le poids propre des ouvrages et d'alléger les charges transmises aux fondations, tout en améliorant les performances thermiques par rapport au béton ordinaire. Le béton léger constitue ainsi une réponse adaptée aux exigences de confort et d'efficacité énergétique des systèmes constructifs contemporains [1].

Ce chapitre a pour objectif d'établir une synthèse bibliographique sur les bétons légers. Plus spécifiquement, il s'agit de définir les critères de classification selon les normes internationales, d'identifier l'influence des différents constituants, liants, granulats légers et additions minérales, sur la microstructure et le comportement du matériau, et d'évaluer les corrélations entre la masse volumique et les propriétés mécaniques et thermiques à l'état durci.

### 1.1 Généralités sur les bétons légers :

#### 1.1.1 Définition et concepts fondamentaux :

Le béton léger est un type de béton spécial qui trouve de nouvelles applications grâce à ses propriétés avantageuses. Il se distingue du béton ordinaire par sa densité plus faible. La masse volumique d'un béton ordinaire est comprise entre  $2\ 200$  et  $2\ 600 \text{ kg/m}^3$ , tandis que celle d'un béton léger est comprise entre  $300$  et  $1850 \text{ kg/m}^3$  [1].



**Figure 1.1** : Différents types de bétons légers [2]

Les bétons légers couvrent une large gamme de propriétés, résumées dans le tableau.1 :

**Tableau 1.1** : Comparaison des propriétés physiques et mécaniques entre le béton léger et le béton ordinaire [1].

| Propriété                                              | Béton léger | Béton ordinaire |
|--------------------------------------------------------|-------------|-----------------|
| Masse volumique sèche ( $\text{kg/m}^3$ )              | 300 – 1850  | 2 200 – 2 600   |
| Résistance en compression (MPa)                        | 1 – 60      | 15 – 100        |
| Conductivité thermique ( $\text{W/m} \cdot \text{K}$ ) | 0,2 – 1,0   | 1,6 – 1,9       |

### 1.1.2 Historique :

Le béton de granulats légers (LWAC) n'est pas une invention récente, mais une technique dont les racines remontent à l'Antiquité. Son histoire débute au troisième millénaire avant J.-C., lorsque les Sumériens ont utilisé des granulats naturels d'origine volcanique pour la construction de Babylone. Par la suite, les Grecs et les Romains ont exploité la pierre ponce pour édifier des structures monumentales dont certaines subsistent encore de nos jours, telles que le Panthéon (118–128 apr. J.-C.) et le Colisée (70–82 apr. J.-C.). Afin de réduire le poids de leur Opus Caementitium, les Romains recouraient également à des vases en terre cuite creux intégrés dans la maçonnerie [3].

Au XIXe siècle, l'Allemagne a marqué le début du développement des granulats synthétiques, notamment avec Kukenthal, qui a obtenu un brevet en 1880 pour la production de pièces d'argile poreuse. L'ère moderne a ensuite connu un tournant décisif en 1918, lorsque Stephen J. Hayde, aux États-Unis, a breveté un procédé de production d'argile expansée par four rotatif. Cette innovation a ouvert la voie à une expansion industrielle mondiale et à la création d'instituts spécialisés dans les années 1950, posant ainsi les bases du développement contemporain des bétons légers [3].



**Figure 1.2 :** colisée de Rome



**Figure 1.3 :** Panthéon de Rome

### 1.1.3 Classification normative des bétons légers et caractéristiques associées :

L'intérêt majeur du béton léger réside dans sa capacité à se substituer au béton ordinaire afin de réduire les charges permanentes des structures. Cette réduction du poids propre permet d'optimiser le dimensionnement des éléments structuraux et des fondations, générant ainsi des économies substantielles sur le coût global du projet. Selon la norme européenne EN 206-1, les bétons légers sont classifiés en six catégories en fonction de leur masse volumique apparente sèche, comme le présente le tableau 1.2

**Tableau 1.2 :** Classification des bétons légers en fonction de la masse volumique [4]

| Classe de masse volumique | LC1,0           | LC1,2            | LC1,4            | LC1,6            | LC1,8            | LC2,0            |
|---------------------------|-----------------|------------------|------------------|------------------|------------------|------------------|
| Kg/m <sup>3</sup>         | > 800 et ≤ 1000 | > 1000 et ≤ 1200 | > 1200 et ≤ 1400 | > 1400 et ≤ 1600 | > 1600 et ≤ 1800 | > 1800 et ≤ 2100 |

Sur le plan des performances, les propriétés mécaniques et thermiques du béton léger sont étroitement liées à sa masse volumique. Bien qu'une densité réduite entraîne généralement une diminution de la résistance à la compression et du module d'élasticité, les bétons légers à haute résistance (HSLWC) font exception en atteignant des résistances dépassant 40 MPa pour une masse volumique inférieure à 2000 kg/m<sup>3</sup>. Par ailleurs, la structure allégée du béton léger lui confère d'excellentes performances thermiques, en raison de la relation inverse qui existe entre la masse volumique et la conductivité thermique. Avec une conductivité thermique variant entre 0,2 et 1,0 W/m K, le béton léger offre des performances d'isolation nettement supérieures à celles du béton ordinaire, dont la conductivité oscille entre 1,6 et 1,9 W/m K. Ce matériau concilie ainsi efficacement performance structurelle et efficacité énergétique, répondant aux exigences croissantes du génie civil durable [4].

## 1.2 Constituants et méthodes de formulation des bétons légers :

La formulation du béton léger consiste à déterminer la composition optimale des constituants (granulats, liant et eau) afin d'atteindre les propriétés mécaniques et physiques souhaitées. Ce processus se déroule en trois étapes fondamentales : la définition de la nature et des exigences de l'ouvrage, la détermination des propriétés cibles du béton, puis le calcul des dosages des constituants. Il convient de souligner qu'aucune méthode de formulation ne permet d'obtenir directement une composition finale sans ajustement préalable par des essais en laboratoire [5].

La formulation dépend en premier lieu de la nature de l'ouvrage, qui conditionne le type de béton léger à utiliser. On distingue à cet égard deux grandes catégories : le béton léger structural, destiné aux

éléments porteurs, et le béton léger architectural, utilisé pour les éléments non structuraux. Le dosage des constituants repose quant à lui sur quatre facteurs fondamentaux interdépendants : la qualité de la pâte de ciment hydraté, la qualité des granulats, la rhéologie recherchée à l'état frais et les propriétés mécaniques visées à l'état durci [5].

### 1.2.1 Liants hydrauliques et additions minérales :

Les liants hydrauliques, dont le ciment Portland constitue le représentant le plus répandu, sont des poudres minérales qui réagissent chimiquement avec l'eau pour former des hydrates, conduisant progressivement au durcissement du mélange. Ces dernières années, le rôle des additions minérales s'est considérablement accru. Des matériaux tels que les cendres volantes, la fumée de silice et le laitier de haut fourneau sont incorporés en substitution partielle du ciment, dans le but d'améliorer les propriétés du béton à l'état frais et durci. Ces additions réagissent avec la chaux libre libérée lors de l'hydratation pour former de nouveaux composés silicatés (C-S-H), réduisant ainsi la porosité et améliorant la durabilité du matériau [5].

Les principales additions minérales utilisées dans la formulation des bétons légers sont les suivantes [6] :

**a.Cendres volantes** :Sous-produits issus de la combustion du charbon, elles améliorent l'ouvrabilité du béton frais et accroissent sa résistance à long terme grâce à leur activité pouzzolanique.



Figure 1.4 : Cendres volantes [7]

**b.Fumée de silice** :Co-produit de la fabrication du silicium en four à arc électrique, ses particules ultrafines optimisent l'empilement granulaire et réduisent la porosité du béton, tandis que sa réactivité pouzzolanique améliore ses propriétés mécaniques et sa durabilité.



Figure 1.5 : Fumée de silice [8]

**c.Laitier de haut fourneau (GGBS)** :sous-produit de la métallurgie de la fonte, il se substitue partiellement au ciment Portland et confère au béton une meilleure résistance chimique tout en limitant l'échauffement dû à l'hydratation, ce qui le rend particulièrement adapté aux ouvrages massifs.



**Figure 1.6** : Laitier de haut fourneau (GGBS) [9]

**d.Métakaolin** :produit de la calcination du kaolin à haute température, il réagit rapidement avec la portlandite libérée lors de l'hydratation du ciment, densifiant ainsi la microstructure du béton et améliorant ses performances mécaniques dès les jeunes âges.



**Figure 1.7** : Métakaolin [10]

### 1.2.2 Granulats légers :

Les granulats légers constituent le composant principal du béton léger, occupant environ 70 % de son volume et formant son squelette résistant. Selon les normes européennes, ces granulats qu'ils soient d'origine naturelle, artificielle ou recyclée doivent être propres, durs et exempts d'impuretés chimiques susceptibles d'entraver le processus d'hydratation ou d'affaiblir l'adhérence avec la pâte de ciment. Leurs propriétés influencent directement le comportement du béton à l'état frais et durci : les grains de forme régulière favorisent la stabilité du mélange, tandis que les grains anguleux et rugueux, bien qu'ils nécessitent davantage d'eau et de ciment, offrent une meilleure cohésion interfaciale [5].

Parmi les propriétés physiques les plus déterminantes figurent la masse volumique et le coefficient d'absorption d'eau. Leur porosité élevée engendre une forte capacité d'absorption, nécessitant un ajustement précis de l'eau de gâchage pour garantir la stabilité de la résistance mécanique et de l'ouvrabilité. Ces granulats doivent également présenter une durabilité suffisante face au gel, à l'abrasion et aux températures élevées, tout en étant exempts de minéraux réactifs susceptibles de provoquer des réactions nocives telles que la réaction alcali-granat (RAG) [5]. Ils se caractérisent par une masse

volumique apparente inférieure à  $1000 \text{ kg/m}^3$ , variant entre  $10 \text{ kg/m}^3$  pour le polystyrène expansé et  $900 \text{ kg/m}^3$  pour la pouzzolane, ce qui permet de réduire considérablement le poids propre du béton, bien que cette légèreté s'accompagne généralement d'une diminution des performances mécaniques. Ces granulats se répartissent en trois grandes familles : les granulats naturels, les granulats artificiels et les granulats légers recyclés. [5].

#### 1.2.2.1 Granulats légers naturels :

- a. Pierre ponce : La pierre ponce est une roche naturelle d'origine volcanique, composée principalement de silice, d'alumine et d'alcalis. Elle se forme lors du refroidissement rapide de roches en fusion et se présente sous forme de grains arrondis de couleur grisâtre, dont le diamètre varie de 10 à 20 mm selon les gisements. Sa masse volumique sèche est faible, comprise entre 500 et  $800 \text{ kg/m}^3$ , en raison de la porosité engendrée par les bulles de gaz lors de sa formation. Assez friable, elle est principalement utilisée pour la confection de bétons légers d'isolation et de structure à résistances modestes, ainsi que dans les enduits légers. Le tableau 1.3 présente ses principales propriétés mécaniques et physiques [5].



**Figure 1.8 :** Pierre ponce

**Tableau 1.3 :** Propriétés du béton léger confectionné à partir de pierre ponce [5].

| Type  | $\rho$<br>( $\text{kg/m}^3$ ) | Résistance à<br>la<br>compression<br>(MPa) | Résistance<br>à la<br>traction<br>(MPa) | E<br>(GPa) | Retrait<br>(mm/m) | Dilatation<br>(mm/m)   | $\lambda$<br>(kcal/mh°C) |
|-------|-------------------------------|--------------------------------------------|-----------------------------------------|------------|-------------------|------------------------|--------------------------|
| Ponce | 750-1400                      | 3-20                                       | 0,5-1,5                                 | 2-10       | 1,0-1,5           | $8 - 9 \times 10^{-6}$ | 0,40                     |

- b. Pouzzolane : La pouzzolane est une roche silico-alumineuse d'origine volcanique, formée lors de la cristallisation lente du magma scories, laves mousseuses et crasses volcaniques. Extraite en carrière puis lavée, concassée et criblée, sa couleur varie du rouge brun au noir. Sa composition chimique typique comprend environ 50 % de  $\text{SiO}_2$ , 20 % d' $\text{Al}_2\text{O}_3$  et 10 % de  $\text{Fe}_2\text{O}_3$ . Sa masse volumique, comprise entre 700 et  $900 \text{ kg/m}^3$ , est légèrement supérieure à celle de la pierre ponce, ce qui confère aux bétons fabriqués à partir de ce granulat des densités et des résistances mécaniques légèrement plus élevées [5].



Figure 1.9 : Pouzzolane

#### 1.2.2.2 Granulats légers artificiels :

- a. Argile expansée : L'argile expansée est produite par cuisson à haute température d'argiles sélectionnées contenant de la pyrite, de l'hématite ou de la dolomie. Le processus d'expansion génère des particules généralement sphériques, recouvertes d'une peau brun rougeâtre et présentant une texture alvéolaire interne. Ce type de granulat offre un excellent équilibre entre légèreté et performances mécaniques, comme l'illustre le tableau 1.4 [5].

Tableau 1.4 : Propriétés du béton léger confectionné à partir d'argile expansée [5].

| Type               | $\rho$<br>(kg/m <sup>3</sup> ) | Résistance<br>à la<br>compression<br>(MPa) | Résistance<br>à la<br>traction<br>(MPa) | E<br>(GPa) | Retrait<br>(mm/m) | Dilatation<br>(mm/m)   | $\lambda$<br>(kcal/mh°C) |
|--------------------|--------------------------------|--------------------------------------------|-----------------------------------------|------------|-------------------|------------------------|--------------------------|
| Argile<br>expansée | 600-1800                       | 5-35                                       | 4-8                                     | 6-20       | 0,3-0,6           | $6 - 7 \times 10^{-6}$ | 0,2-0,75                 |

- b. Schiste expansé : Les schistes expansés sont obtenus par traitement thermique de schistes naturels d'origine carbonifère, houillère ou bitumineuse. Les bétons légers incorporant ce type de granulat se distinguent par des masses volumiques et des résistances à la compression particulièrement élevées au sein de la famille des bétons légers, avec des résistances pouvant dépasser 50 MPa et un module d'élasticité excédant 20 GPa, les rendant ainsi bien adaptés aux applications structurales. Leurs caractéristiques sont récapitulées dans le tableau 1.5 [5].



Figure 1.10 : Schiste expansé

Tableau 1.5 : Propriétés du béton léger confectionné à partir de schiste expansé [5].

| Type                | $\rho$<br>(kg/m <sup>3</sup> ) | Résistance<br>à la<br>compression<br>(MPa) | Résistance<br>à la<br>traction<br>(MPa) | E<br>(GPa) | Retrait<br>(mm/m) | Dilatation<br>(mm/m)   | $\lambda$<br>(kcal/mh°C) |
|---------------------|--------------------------------|--------------------------------------------|-----------------------------------------|------------|-------------------|------------------------|--------------------------|
| Schiste<br>expansée | 800-1800                       | 10 à 50                                    | 10 à 15                                 | > 20       | 0,5 à 0,7         | 6 à $7 \times 10^{-6}$ | 0,15 à 0,6               |

c. Billes de polystyrène expansé : Les billes de polystyrène sont produites à partir de granules non expansés contenant un agent gonflant. Les bétons confectionnés avec ce type de granulat présentent une très faible masse volumique, comprise entre 300 et 1000 kg/m<sup>3</sup>, avec des performances mécaniques modestes (résistance à la compression de 1 à 10 MPa). Il a été établi que la masse volumique des billes n'influe pas significativement sur les propriétés mécaniques du béton obtenu [5]. Le tableau 1.6 résume leurs principales propriétés.



Figure 1.11 : Billes de polystyrène expansé

**Tableau 1.6 :** Propriétés du béton léger confectionné à partir de billes de polystyrène [5].

| Type        | $\rho$<br>(kg/m <sup>3</sup> ) | Résistance<br>à la<br>compression<br>(MPa) | Résistance<br>à la<br>traction<br>(MPa) | E<br>(GPa) | Retrait<br>(mm/m) | Dilatation<br>(mm/m) | $\lambda$<br>(kcal/mh°C) |
|-------------|--------------------------------|--------------------------------------------|-----------------------------------------|------------|-------------------|----------------------|--------------------------|
| polystyrène | 300-1000                       | 1 à 10                                     | 0,3 à 1,5                               | 2          | 1,0 à 2,0         | $10 \times 10^{-6}$  | 0,05 à 0,25              |

### 1.2.2.3 Granulats légers recyclés :

L'incorporation de polymères recyclés, plastiques et caoutchoucs, dans la matrice cimentaire fait l'objet d'un intérêt croissant dans la communauté scientifique. Sans couvrir l'ensemble des paramètres de formulation, ces matériaux contribuent à améliorer certaines propriétés mécaniques, notamment la ductilité et la résistance aux chocs. Néanmoins, afin de ne pas compromettre l'intégrité structurelle du béton léger, la littérature recommande de limiter leur taux de substitution à 15–20 % de la masse des granulats fins [5].

Sur le plan technico-économique, deux options se distinguent :

- Le plastique :** disponible sous forme de granulats artificiels, son usage industriel reste limité par la forte volatilité de son prix, indexé sur les cours mondiaux des résines, ce qui rend le coût de production difficile à maîtriser.
- Le caoutchouc (issu de pneus usagés) :** cette alternative présente des avantages plus marqués. Son coût est sensiblement inférieur à celui du plastique, de deux à cinq fois moins cher, et sa valorisation répond aux exigences du développement durable en détournant des déchets polluants de l'enfouissement. Par ailleurs, la diversité des fournisseurs et la régularité de l'approvisionnement garantissent une stabilité des coûts et un rapport qualité-prix compétitif. Avant d'entamer la phase de formulation, une sélection rigoureuse des constituants s'impose afin d'assurer les performances visées. Le tableau 1.7 récapitule les catégories de granulats retenues, en précisant pour chacune le matériau sélectionné ainsi que les justifications techniques et économiques ayant guidé ce choix.

**Tableau 1.7 :** Récapitulatif des granulats sélectionnés pour la formulation du béton léger [5].

| Type de granulat     | Matériau retenu           | Justification du choix                                                                                                                                                 |
|----------------------|---------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <b>Conventionnel</b> | Sable                     | <ul style="list-style-type: none"> <li>Contribution à la résistance mécanique, à la cohésion du mélange et à la qualité du parement</li> </ul>                         |
| <b>Léger</b>         | Polystyrène expansé       | <ul style="list-style-type: none"> <li>Réduction de la masse volumique, bonne disponibilité, ainsi que performances thermiques et acoustiques intéressantes</li> </ul> |
| <b>Recyclé</b>       | Caoutchouc (pneus usagés) | <ul style="list-style-type: none"> <li>Coût réduit, légèreté, disponibilité régulière et valorisation de déchets industriels</li> </ul>                                |

### 1.2.3 Adjuvants :

Dans la technologie contemporaine du béton, les adjuvants chimiques constituent des composants essentiels pour l'atteinte des performances visées. Ces produits agissent sur les propriétés physiques et chimiques du mélange, régulation du temps de prise, réduction de la demande en eau, amélioration de la fluidité ou introduction contrôlée d'air occlus. Bien que leur gamme soit étendue, la confection du béton léger fait principalement appel à trois familles [5].

#### a. Les agents entraîneurs d'air :

Généralement formulés à partir de sels d'acides gras, ces agents génèrent un réseau de microbulles d'air uniformément réparties dans la pâte cimentaire. À l'état frais, ils améliorent l'ouvrabilité du mélange ; à l'état durci, ils confèrent au béton une meilleure résistance aux cycles de gel-dégel, y compris en présence de sels de déverglaçage [5].

#### b. Les agents moussants :

Ces adjuvants permettent d'incorporer une quantité importante d'air dans le mortier afin de réduire significativement la masse volumique du béton. On distingue deux catégories techniques :

- CLSM : taux d'air pouvant atteindre 30 %, donnant des bétons de densité supérieure à 800 kg/m<sup>3</sup>.
- LD-CLSM : taux d'air pouvant atteindre 70 %, produisant des bétons ultra-légers de densité inférieure à 800 kg/m<sup>3</sup>.

Composés de protéines hydrolysées ou de résines savonneuses, ces agents nécessitent une vitesse de malaxage élevée pour assurer une distribution homogène des bulles. Ils sont incorporés au mélange soit directement sous forme liquide ou pulvérulente, soit après transformation en mousse par pistolet spécialisé [5].

#### c. Les Super Plastifiants :

Les superplastifiants agissent en abaissant le rapport eau/liant sans réduire la fluidité du mélange, ce qui se traduit par une amélioration de la résistance à la compression et une meilleure mise en œuvre. Ces polymères synthétiques à masse moléculaire contrôlée assurent une dispersion efficace des grains de ciment sans perturber le temps de prise ni introduire d'air indésirable [4].

On distingue historiquement les plastifiants à base de mélamine sulfonée (PMS) et de naphthalène sulfoné (PNS), auxquels s'ajoutent les formulations modernes à base de polycarboxylates. Leur mécanisme d'action repose sur l'adsorption des molécules polymères à la surface des grains de ciment, leur conférant des charges électrostatiques identiques qui provoquent une répulsion mutuelle. Cette dispersion libère l'eau interstitielle piégée dans les agglomérats et augmente ainsi la mobilité de l'ensemble du mélange [4].

### 1.2.4 Eau de gâchage :

L'eau de gâchage joue un rôle particulièrement déterminant dans la formulation des bétons légers, en raison du fort pouvoir absorbant des granulats utilisés, tels que l'argile expansée, pouvant absorber entre 10 % et 30 % de leur propre poids en eau. Il convient à cet égard de distinguer deux notions fondamentales : l'eau totale, correspondant à la quantité d'eau introduite dans le mélange, et l'eau efficace, qui représente la quantité réellement disponible pour l'hydratation du ciment et la maniabilité du béton frais, après déduction de l'eau absorbée par les granulats.

Afin d'éviter le dessèchement du mélange ou la perte de résistance liée à l'absorption excessive d'eau par les granulats, il est recommandé de pré-saturer les granulats avant le malaxage. Des études ont montré qu'un pré-mouillage des granulats légers pendant 30 minutes permet d'atteindre des résistances à la compression optimale, en limitant la formation de micropores dans la zone de transition interfaciale entre le granulat et la pâte de ciment. En revanche, l'absence de pré-mouillage conduit à une absorption excessive d'eau au jeune âge, entraînant une hydratation incomplète du ciment et une réduction significative de la résistance mécanique du béton [11].

### 1.3 Types de bétons légers :

La réduction de la masse volumique du béton peut être obtenue par trois approches distinctes, selon la localisation des vides d'air introduits dans le matériau : dans les granulats eux-mêmes, dans la pâte de ciment, ou entre les gros granulats par élimination des granulats fins. Ces trois approches donnent naissance à trois grandes catégories de bétons légers, illustrées schématiquement dans la figure 1.12 [12] :

- Bétons de granulats légers : les vides sont contenus dans les granulats poreux.
- Bétons cellulaires : les vides sont introduits dans la pâte de ciment sous forme de bulles d'air.
- Bétons caverneux (sans fines) : les vides sont créés entre les gros granulats par suppression des granulats fins.



Figure 1.12 : Types de bétons légers [12]

#### 1.3.1 Béton à granulats légers :

Le béton de granulats légers est l'une des techniques les plus anciennes du génie civil, dont les origines remontent à l'Antiquité. Sa composition repose sur l'intégration de granulats légers d'origine naturelle tels que la pouzzolane et la perlite, ou artificielle tels que l'argile expansée, le verre expansé et les cendres volantes frittées. L'intérêt structural de ce béton réside dans sa capacité à réduire significativement les charges permanentes des structures, ce qui en fait un matériau de choix pour la réalisation d'éléments structurels tels que les poteaux, les poutres et les dalles, tout en améliorant l'isolation thermique et l'absorption acoustique des bâtiments [13].

Sur le plan des performances, ce béton présente une grande flexibilité de mise en œuvre, que ce soit par coulage en place ou par préfabrication. Sa masse volumique sèche varie généralement entre 1200 et 2000 kg/m<sup>3</sup>, tandis que sa résistance à la compression peut atteindre des valeurs comprises entre 25 et 80 MPa, illustrant la relation directe entre la densité et la capacité portante du matériau [13].

### 1.3.2 Béton cellulaire :

Le béton cellulaire est issu d'un processus de recherche et développement s'étendant sur plus d'un siècle, dont les prémices scientifiques reposent sur les travaux de Zernikov sur les mortiers de chaux et de sable traités thermiquement. Ce matériau est constitué d'un mélange de ciment Portland et de sable siliceux, et se distingue par sa structure poreuse résultant de l'introduction de fines bulles d'air dans la pâte cimentaire. Cette aération est obtenue par des réactions chimiques contrôlées faisant intervenir des agents tels que la poudre d'aluminium ou des solutions moussantes, exigeant une grande précision dans le dosage et les conditions de fabrication [1, 14].

Ses performances mécaniques sont étroitement liées à sa masse volumique : la résistance à la compression et le module d'élasticité augmentent proportionnellement avec la densité sèche, comme l'illustre le tableau 1.8. La résistance à la flexion peut être améliorée par l'ajout d'armatures ou de microfibres, qui contribuent au contrôle de la microfissuration sous charge. Grâce à ses propriétés d'isolation thermique, sa légèreté et sa facilité de façonnage, le béton cellulaire constitue une solution économique particulièrement adaptée aux travaux de remplissage des murs, des dalles et des planchers, ainsi qu'aux opérations de remblai structurel [1, 14].

**Tableau 1.8 :** Propriétés mécaniques et thermiques des bétons cellulaires en fonction de la masse volumique [5].

| Masse volumique sèche ( $\text{kg/m}^3$ ) | Résistance à la compression (MPa) | Résistance à la flexion (MPa) | Module d'élasticité (GPa) | Conductivité thermique ( $\text{J/m}^\circ\text{C}$ ) |
|-------------------------------------------|-----------------------------------|-------------------------------|---------------------------|-------------------------------------------------------|
| 450                                       | 3.2                               | 0.65                          | 1.6                       | 0.12                                                  |
| 525                                       | 4.0                               | 0.75                          | 2.0                       | 0.14                                                  |
| 600                                       | 4.5                               | 0.85                          | 2.4                       | 0.16                                                  |
| 675                                       | 6.3                               | 1.00                          | 2.5                       | 0.18                                                  |
| 750                                       | 7.5                               | 1.25                          | 2.7                       | 0.20                                                  |

### 1.3.3 Béton caverneux (béton sans fines) :

La formulation du béton caverneux repose sur l'exclusion totale ou partielle du sable du mélange, conduisant à la formation d'une structure de gros granulats enrobés d'une fine couche de pâte de ciment dont l'épaisseur varie entre 1 et 3 mm. Cette configuration génère de larges vides interconnectés qui confèrent au matériau d'excellentes propriétés drainantes et réduisent sa densité, au prix d'une résistance à la compression plus faible que celle du béton conventionnel [1, 5, 12].

Sur le plan mécanique, la résistance à la compression de ce type de béton varie entre 1,5 et 14 MPa, tandis que la résistance à la flexion atteint environ 30 % de la résistance à la compression, proportion supérieure à celle observée pour le béton ordinaire. Ce matériau présente également un faible retrait et une bonne résistance au gel. En revanche, sa forte capacité d'absorption d'eau le rend inadapté aux fondations ou aux zones soumises à une saturation prolongée. Il est largement utilisé dans la construction de murs porteurs pour les bâtiments résidentiels, les panneaux de remplissage, les ouvrages hydrauliques de drainage et les éléments architecturaux [1, 5, 12].




Figure 1.13 : Différents types de béton caverneux [5]

## 1.4 Propriétés des bétons légers :

Le béton léger se distingue par un ensemble de propriétés physiques, mécaniques et thermiques qui en font un matériau d'ingénierie particulièrement adapté aux exigences de la construction contemporaine. Ses atouts ne se limitent pas au seul allègement de la structure portante ; ils englobent également une efficacité thermique notable et des perspectives économiques intéressantes.


### 1.4.1 Propriétés physiques :

#### 1.4.1.1 masse volumique :

La masse volumique représente l'un des paramètres fondamentaux caractérisant le béton léger à l'état durci. Elle conditionne directement la classification du matériau et détermine son domaine d'application. Selon la norme, trois catégories sont distinguées [1] :

- Béton léger de structure** : masse volumique comprise entre 1 350 et 1 900 kg/m<sup>3</sup>, avec une résistance à la compression d'au moins 17 MPa, le rendant apte aux usages porteurs.
- Béton de résistance modérée** : résistance à la compression comprise entre 7 et 17 MPa.
- Béton léger d'isolation** : masse volumique comprise entre 300 et 800 kg/m<sup>3</sup> et résistance inférieure à 7 MPa, destiné essentiellement à l'isolation thermique sans vocation structurelle.

La masse volumique sèche varie sensiblement selon la nature du granulat léger incorporé (vermiculite, perlite, argile expansée, etc.), comme l'illustre la figure 4.23.



**Figure 1.14 :** Masse volumique sèche de bétons légers confectionnés avec différents granulats légers à 28 jours [1]

#### 1.4.1.2 Porosité :

Le béton est un matériau hétérogène constitué d'une phase solide (granulats et liant hydraté) et d'un réseau de vides dont les dimensions s'échelonnent de l'échelle de l'angström (Å) à plusieurs millimètres. Trois niveaux de porosité sont généralement identifiés [15] :

- Porosité intrinsèque du granulat ( $\Phi_g$ ) :** correspond à l'air occlus à l'intérieur des particules de granulats. La taille des capillaires étant de l'ordre de 10  $\mu\text{m}$ , cette porosité est de nature microscopique.
- Porosité intrinsèque du liant ( $\Phi_i$ ) :** se développe au cours de l'hydratation et du séchage de la pâte cimentaire. La taille des pores varie selon leur origine : de 0,01 à 5  $\mu\text{m}$  pour les vides entre hydrates ( $\text{C-S-H}$ ,  $\text{Ca(OH)}_2$ ), et jusqu'à 1 mm pour les bulles générées par un entraîneur d'air. Elle est définie par :

$$\Phi_i = \frac{V_{\text{vide}}}{V_{\text{liant}}} \quad (1.1)$$

Avec  $V_{\text{vide}}$  le volume des vides dans la matrice liante ( $\text{m}^3$ ) et  $V_{\text{liant}}$  le volume total de la pâte de liant ( $\text{m}^3$ ).

- Porosité mésoscopique ( $\Phi_{\text{meso}}$ ) :** résulte de l'arrangement spatial des constituants et représente les vides interfaciaux entre granulats et liant. Elle est calculée par :

$$\Phi_{\text{meso}} = \frac{V_{\text{vides}}}{V_t} \quad (1.2)$$

Avec  $V_{\text{vides}}$  le volume des vides hors porosité intra-liant et intra-granulat ( $\text{m}^3$ ) et  $V_t$  le volume total du matériau ( $\text{m}^3$ ).




Figure 1.15 : Porosité du béton [15]

## 1.4.2 Propriétés mécaniques :

### 1.4.2.1 Résistance à la compression :

Grâce aux avancées en technologie du béton, il est désormais possible d'atteindre, avec des granulats légers, des niveaux de résistance à la compression comparables à ceux des bétons conventionnels. L'incorporation d'additions minérales actives, fumée de silice, cendres volantes, laitier, combinée à l'utilisation de superplastifiants, permet d'abaisser significativement le rapport eau/liant tout en préservant une ouvrabilité satisfaisante. Des résistances à la compression pouvant atteindre 100 MPa ont ainsi été rapportées dans la littérature [16].




Figure 1.16 : Relation entre la résistance à la compression à 28 jours et la masse volumique du béton frais pour des mélanges à granulats légers [16]

### 1.4.2.2 Résistance à la traction :

Tout comme les bétons ordinaires, les bétons à granulats légers présentent une résistance à la traction relativement faible, les fissures pouvant se propager à travers les granulats eux-mêmes. Des valeurs de

résistance à la traction par fendage comprises entre 3,3 et 4,2 MPa ont été relevées pour des bétons de masse volumique 1 940 kg/m<sup>3</sup>, tandis que des valeurs allant de 3,5 à 5,6 MPa ont été enregistrées pour des bétons dont la masse volumique varie entre 1 620 et 1 885 kg/m<sup>3</sup> [17].

#### 1.4.2.3 Module d'élasticité :

Pour un rapport eau/liant équivalent, le module d'élasticité des bétons légers reste inférieur à celui des bétons ordinaires. Cette différence s'explique par la rigidité intrinsèquement plus faible des granulats légers, dont le module d'élasticité se situe entre 10 et 20 GPa, contre 10 à 70 GPa pour le granite et 10 à 55 GPa pour le calcaire. Par ailleurs, comme le met en évidence la figure 1.17, le module d'élasticité des bétons légers présente une corrélation étroite avec leur masse volumique [12].




Figure 1.17 : Valeurs du module d'élasticité de bétons légers à 28 jours issues de différentes études [12]

#### 1.4.3 Propriétés thermiques :

La faible conductivité thermique représente l'un des atouts majeurs du béton léger. Sa porosité élevée limite le transfert de chaleur à travers le matériau, lui conférant des performances d'isolation supérieures à celles du béton conventionnel. Cette propriété est quantifiée par le coefficient de conductivité thermique ( $\lambda$ ), dont la valeur est d'autant plus faible que le béton est sec, l'humidité augmentant sensiblement les transferts thermiques. Le tableau 1.9 regroupe les valeurs de  $\lambda$  pour différents types de bétons légers. On constate que le béton caverneux, de par sa forte porosité, présente le coefficient le plus bas (0,30 Kcal/m/h/°C), tandis que les bétons incorporant du sable de rivière atteignent des valeurs plus élevées, jusqu'à 0,75 Kcal/m/h/°C [4].

**Tableau 1.9 :** Coefficient de conductivité thermique  $\lambda$  en fonction de la masse volumique sèche [4].

| Type                                             | Masse volumique sèche (kg/m <sup>3</sup> ) | $\lambda$<br>(Kcal/m/h/°C) |
|--------------------------------------------------|--------------------------------------------|----------------------------|
| Béton caverneux normal                           | 800-1 000                                  | 0,30                       |
| Béton plein avec sable léger                     | 1 000-1 200                                | 0,40                       |
| Béton plein avec sable léger et sable de rivière | 1 200-1 400                                | 0,60                       |
| Béton plein avec sable de rivière                | 1 400-1 600                                | 0,75                       |

#### 1.4.4 Propriétés acoustiques :

Le comportement acoustique d'un matériau dépend de son interaction avec les ondes sonores, qui peuvent être réfléchies, transmises ou absorbées. Les matériaux traditionnels exploitent la « loi de masse », leur densité élevée faisant obstacle à la propagation des vibrations, avantage dont ne dispose pas le béton léger en raison de sa faible masse volumique. Ce dernier assure néanmoins une isolation acoustique par deux mécanismes distincts :

- a. **La réflexion :** une surface imperméable renvoie les ondes sonores vers leur source, limitant ainsi leur transmission.
- b. **L'absorption acoustique :** l'énergie sonore est dissipée à l'intérieur du matériau par friction visqueuse, ce qui requiert une porosité ouverte et une perméabilité suffisante permettant aux ondes de pénétrer et de s'amortir progressivement. Compte tenu de la complexité de ces mécanismes et de leur sensibilité aux paramètres de formulation, la caractérisation acoustique du béton léger repose essentiellement sur l'expérimentation en laboratoire [15].

#### 1.4.5 Durabilité :

Les conditions d'exposition constituent un facteur déterminant dans la conception et la formulation du béton léger. Parmi les agressions les plus critiques figure l'action des cycles de gel-dégel, avec ou sans sels de déverglaçage, qui conditionne fortement la tenue du matériau aux sollicitations climatiques. Il convient de distinguer ces deux types d'attaque, dans la mesure où leurs mécanismes de dégradation diffèrent sensiblement et n'affectent pas la microstructure du béton de la même manière [18].

### 1.5 Avantages et limites des bétons légers :

Le béton léger présente à la fois des avantages notables et des limitations qu'il est important de prendre en compte avant tout choix de formulation.

#### 1.5.1 Avantages du béton léger :

Les avantages du béton léger peuvent être regroupés en trois catégories principales [1] :

##### a. Avantages techniques :

- Performances d'isolation thermique et acoustique supérieures à celles du béton conventionnel.

- Bonne durabilité chimique grâce à sa composition à pH basique (ciment, sables lavés, billes de polystyrène expansé stabilisé), le rendant imputrescible.
- Qualité de finition de surface satisfaisante, comparable aux bétons classiques.

**b. Avantages de mise en œuvre :**

- Exécution rapide : le chantier est accessible entre 24 et 48 heures après le coulage, selon l'épaisseur de la dalle.
- Bonne ouvrabilité : le matériau peut être pompé sur de longues distances et à des hauteurs importantes, facilitant sa mise en œuvre, y compris pour les fortes épaisseurs.
- Réduction du poids des coffrages, simplifiant leur conception et leur manutention.


**c. Avantages économiques :**

- Amélioration de la productivité sur chantier grâce à la réduction de la masse des éléments manipulés.
- Allègement de la structure portante, permettant de réduire les dimensions et le coût des fondations.

### 1.5.2 Inconvénients :

Le béton léger présente néanmoins plusieurs limitations d'ordre technique, structural et économique [1] :

- Sur le plan mécanique, ses résistances et son module d'élasticité restent inférieurs à ceux du béton ordinaire, le rendant plus sensible aux déformations et à la flexion.
- Sur le plan structural, ce matériau souffre d'un manque de ductilité marqué. Comme l'illustre la figure 1.18, la courbe contrainte-déformation révèle un comportement fragile caractérisé par une rupture soudaine dès l'atteinte de la charge limite. Cette fragilité est d'autant plus prononcée lorsque le mélange est constitué exclusivement de granulats légers (courbe A), comparativement au mélange hybride intégrant des granulats fins ordinaires (courbe B). Une telle caractéristique impose une rigueur d'exécution accrue sur chantier, en particulier pour les éléments structuraux de grandes dimensions.
- Sur le plan économique, le coût au mètre cube est plus élevé que celui du béton ordinaire, en raison du recours à des granulats manufacturés expansés dont le prix de production est plus important.



**Figure 1.18 :** Courbes contrainte-déformation de bétons légers à base d'argile expansée : (A) granulats fins et grossiers légers ; (B) granulats fins ordinaires [19]

## 1.6 Applications des bétons légers en génie civil :

Le recours aux bétons légers dans le domaine du génie civil s'est considérablement développé grâce à leur faible masse volumique et leurs performances thermiques remarquables. Ces caractéristiques permettent de répondre à des exigences techniques variées, allant de l'allègement des structures massives à l'amélioration de l'efficacité énergétique des bâtiments [1].

### 1.6.1 Bâtiments et éléments structuraux :

- a. **Éléments porteurs** : utilisé dans les poteaux, poutres et voiles porteurs, le béton léger réduit les charges permanentes, offrant la possibilité de construire des niveaux supplémentaires ou de limiter les dimensions des fondations. Sa faible masse contribue également à atténuer les forces sismiques.
- b. **Dalles et planchers** : sa légèreté permet de couvrir de grandes portées avec un poids réduit, le rendant particulièrement adapté aux immeubles de grande hauteur (IGH).
- c. **Façades préfabriquées** : il entre dans la fabrication de panneaux muraux alliant résistance structurelle et isolation thermique intégrée.

### 1.6.2 Ponts et ouvrages d'art :

- a. **Ponts et viaducs** : la réduction du poids propre du tablier diminue le coût des appuis et permet d'accroître la longueur des travées entre piles.
- b. **Structures marines (offshore)** : utilisé dans les plateformes pétrolières flottantes et les ouvrages maritimes, il se distingue par sa flottabilité et sa résistance aux environnements salins agressifs.
- c. **Constructions parasismiques** : en réduisant la masse globale de l'ouvrage, il améliore la réponse dynamique des structures soumises aux sollicitations sismiques.

### 1.6.3 Isolation et réhabilitation :

- a. **Isolation thermique et acoustique** : sa porosité élevée limite les ponts thermiques, améliore l'efficacité énergétique des bâtiments et confère une bonne capacité d'absorption acoustique.
- b. **Renforcement des bâtiments anciens** : il constitue une solution privilégiée pour la restauration et l'extension des bâtiments existants, permettant d'augmenter la capacité portante ou d'ajouter des niveaux sans surcharger les fondations.
- c. **Réhabilitation thermique** : sous forme de couches de revêtement ou de panneaux sandwich, il améliore l'isolation thermique des édifices anciens tout en préservant leur intégrité structurelle.

## 1.7 Synthèse critique des travaux antérieurs :

Cette synthèse s'appuie sur l'analyse des travaux antérieurs afin d'identifier les acquis expérimentaux, les lacunes persistantes et les perspectives offertes par les outils prédictifs modernes pour la caractérisation des bétons légers.

### 1.7.1 Résultats expérimentaux majeurs :

Les travaux antérieurs, notamment ceux de [16] et [12], ont mis en évidence une relation inverse entre la masse volumique et la résistance à la compression. Les bétons légers à hautes performances atteignent des résistances de l'ordre de 40 MPa pour des masses volumiques inférieures à 2 000 kg/m<sup>3</sup>. Pour différents types de granulats légers, argile expansée, pierre ponce notamment, les résistances à la compression relevées varient de 1 à 50 MPa, avec un module d'élasticité réduit compris entre 10 et 20 GPa. Ces résultats sont complétés par des données expérimentales sur les propriétés thermiques et acoustiques, confirmant une conductivité thermique sensiblement inférieure à celle des bétons ordinaires.

### 1.7.2 Besoin d'outils prédictifs :

L'analyse de la littérature révèle que la détermination des propriétés finales des bétons légers est gouvernée par des interactions physico-chimiques complexes, liées à la variabilité des granulats légers et à l'influence des additions minérales et chimiques sur la microstructure du matériau. Les modèles mathématiques classiques, tels que la régression linéaire, s'avèrent insuffisamment précis pour rendre compte de cette complexité. Le recours à l'Intelligence Artificielle (IA), et plus particulièrement aux algorithmes d'Apprentissage Automatique (Machine Learning), s'impose comme une alternative pertinente [20], pour les raisons suivantes :

- a. **Modélisation de comportements complexes :** les réseaux de neurones artificiels (ANN) sont capables d'identifier des relations non linéaires cachées au sein de bases de données expérimentales volumineuses, permettant de simuler avec précision les comportements mécaniques et thermiques du béton [21].
- b. **Optimisation de la formulation :** ces outils permettent de prédire la résistance à la compression et la masse volumique en fonction des paramètres de dosage, réduisant ainsi le recours à des campagnes expérimentales coûteuses et chronophages [20].
- c. **Prédiction de la durabilité :** les modèles d'IA permettent d'extrapoler le comportement à long terme des bétons légers sous conditions environnementales sévères, là où les équations empiriques classiques atteignent leurs limites [20].

C'est dans cette perspective que le chapitre suivant est consacré aux fondements théoriques des algorithmes d'Apprentissage Automatique retenus dans le cadre de cette étude.

## 1.8 Conclusion :

Dans ce premier chapitre, un état de l'art sur les bétons légers a été établi, mettant en évidence la diversité des matériaux regroupés sous cette appellation. De manière générale, l'allègement du béton est obtenu par réduction de sa masse volumique, principalement par introduction d'air, dans les granulats ou dans la pâte de ciment, à l'aide d'adjuvants tels que les agents moussants ou entraîneurs d'air. Bien que le béton léger présente des avantages reconnus, sa résistance mécanique, notamment à la traction et à la compression, reste inférieure à celle du béton ordinaire. La complexité des interactions entre ses constituants rend difficile la prédiction de ses propriétés par les méthodes classiques, ce qui justifie le recours aux outils d'Apprentissage Automatique développés dans les chapitres suivants.

## Chapitre 2

# Fondements théoriques de l'apprentissage automatique et des réseaux de neurones artificiels

C E chapitre expose les fondements théoriques de l'intelligence artificielle et de l'apprentissage automatique, dont l'essor a profondément transformé les approches de résolution des problèmes complexes en génie civil. Une attention particulière est portée à l'évolution historique de ces technologies, depuis les premières formulations algorithmiques jusqu'aux architectures avancées de réseaux de neurones artificiels, dont le fonctionnement s'inspire des systèmes biologiques nerveux. Les principaux algorithmes mobilisés pour la prédiction des propriétés des matériaux de construction y sont présentés, décrits et analysés. La distinction fondamentale entre la programmation classique et l'apprentissage automatique est également abordée, en mettant en évidence la manière dont ces modèles permettent d'améliorer significativement la précision des prédictions dans le domaine de la recherche sur les matériaux et les structures en génie civil.

### 2.1 Intelligence Artificielle :

L'intelligence artificielle est une branche de l'informatique dont l'objectif fondamental est de reproduire, au sein de systèmes logiciels, certaines capacités cognitives propres à l'être humain, telles que l'apprentissage, le raisonnement et la prise de décision. Selon Touzet [22], le principe fondateur de ce domaine repose sur l'élaboration de modèles mathématiques et informatiques capables de traiter l'information de manière non linéaire et de formuler des réponses adaptées à partir des expériences accumulées. Cette approche ouvre de larges perspectives pour la modélisation des relations complexes et non explicites entre les variables d'entrée et les sorties des systèmes étudiés [22]

#### 2.1.1 Définition :

L'intelligence artificielle (IA) désigne le champ scientifique et technique ayant pour ambition de concevoir des systèmes informatiques capables d'imiter certaines fonctions cognitives humaines, telles que l'apprentissage, le raisonnement, la perception et la résolution de problèmes complexes [22]. Dans le cadre de l'approche connexionniste développée par Touzet, l'IA ne se réduit pas à l'exécution d'algorithmes déterministes et rigides, mais englobe la construction de modèles computationnels inspirés

de l'architecture biologique du cerveau humain. Ces modèles sont capables de traiter l'information de façon parallèle et distribuée, et d'adapter leur comportement en réponse à des données nouvelles, par modification progressive des paramètres internes du système [22]. Les objectifs fondamentaux de l'intelligence artificielle s'articulent autour de deux perspectives complémentaires [22] :

- a. **Perspective ingénierie** : Cette vision pragmatique vise à doter les systèmes automatisés de capacités fonctionnelles leur permettant d'accomplir des tâches relevant habituellement de l'intelligence humaine, telles que la planification, la perception sensorielle et la prise de décision dans des environnements dynamiques et incertains.
- b. **Perspective scientifique** : Cette approche cherche à formaliser mathématiquement les mécanismes sous-jacents à l'intelligence naturelle, dans le but de construire des systèmes experts capables d'inférer et de prédire le comportement de systèmes physiques complexes, tels que le comportement mécanique du béton léger à partir de l'expérience accumulée sur des données expérimentales antérieures.

### 2.1.2 Historique :

Depuis son émergence en tant que discipline scientifique autonome, l'intelligence artificielle a traversé plusieurs phases de développement qui ont profondément marqué son évolution et façonné ses orientations actuelles. Ces étapes peuvent être synthétisées comme suit [22] :

- a. **Phase de fondation (1940–1956)** : Les prémices de l'intelligence artificielle remontent aux travaux pionniers d'Alan Turing sur la capacité des machines à simuler le raisonnement humain. Cette période a culminé avec la tenue de la conférence de Dartmouth en 1956, au cours de laquelle le terme « intelligence artificielle » a été officiellement introduit comme dénomination d'un nouveau champ de recherche scientifique dédié à la modélisation des fonctions cognitives humaines par des systèmes informatiques.
- b. **Ère du connexionnisme et premières modélisations (années 1950–1970)** : Comme le souligne Touzet [22], cette période a été marquée par des tentatives sérieuses de formalisation mathématique du neurone biologique, donnant naissance au paradigme connexionniste. L'objectif central était de concevoir des systèmes capables d'apprendre par ajustement itératif des poids synaptiques reliant les unités neuronales artificielles, jetant ainsi les bases des architectures de réseaux de neurones.
- c. **Périodes de stagnation — l'hiver de l'IA (années 1970–1980)** : Le domaine a été confronté à des obstacles techniques et financiers majeurs, liés à l'inadéquation entre les attentes théoriques et les capacités de calcul disponibles à l'époque. Ces limitations ont conduit à ce que la communauté scientifique qualifie « d'hiver de l'IA », caractérisé par une réduction significative des investissements et un ralentissement des avancées de la recherche.
- d. **Révolution contemporaine et essor de l'apprentissage automatique (XXIe siècle)** : L'avènement du XXIe siècle a marqué un tournant décisif, porté par l'augmentation exponentielle de la puissance de calcul, notamment grâce aux unités de traitement graphique (GPU), et par la disponibilité croissante de grandes masses de données (Big Data). Ces conditions ont permis à l'intelligence artificielle de franchir le seuil des applications pratiques à grande échelle, avec l'émergence et la consolidation des algorithmes d'apprentissage profond (Deep Learning) et des méthodes d'apprentissage statistique, qui constituent aujourd'hui les fondements des outils de prédiction et de modélisation les plus performants dans de nombreux domaines scientifiques et d'ingénierie.

### 2.1.3 Importance de l'intelligence artificielle en génie civil :

L'intégration de l'intelligence artificielle dans le domaine du génie civil représente une révolution technologique majeure, offrant des outils performants pour répondre aux défis complexes de la construction moderne. Parmi ses principaux apports, on peut distinguer [23] :

1. **Efficacité de la conception structurelle** : Les algorithmes avancés contribuent à l'amélioration des processus de conception structurelle, réduisant ainsi la consommation de matériaux tout en augmentant la durabilité des structures.
2. **Gestion de projets et prévision des risques** : L'intelligence artificielle offre la capacité d'anticiper les risques, de gérer les calendriers des projets complexes et de diminuer les coûts opérationnels grâce à l'analyse de données massives (Big Data).
3. **Surveillance de l'état de santé des ouvrages (SHM- Structural Health Monitoring)** : Les capteurs intelligents couplés à l'intelligence artificielle permettent la détection précoce des fissures et des défauts sur les ponts et les bâtiments, favorisant ainsi une sécurité accrue et une prolongation de la durée de vie des infrastructures.
4. **Durabilité et développement durable** : L'intelligence artificielle contribue à la réduction de l'empreinte carbone des projets d'ingénierie, par l'optimisation de la consommation énergétique des bâtiments, le choix de matériaux de construction respectueux de l'environnement et l'amélioration des procédés de recyclage des déchets de construction.
5. **Prédiction des propriétés des matériaux** : L'une des applications les plus prometteuses en génie civil est l'utilisation de modèles d'apprentissage automatique pour prédire les propriétés mécaniques et physiques des matériaux de construction, telles que la résistance à la compression, la densité ou le module d'élasticité ; à partir de leur composition. Cette approche réduit considérablement le nombre d'essais expérimentaux nécessaires et accélère le développement de nouveaux matériaux performants.

## 2.2 Machine Learning :


Le machine learning, ou apprentissage automatique, constitue l'une des branches les plus importantes de l'intelligence artificielle. Il repose sur la capacité des machines à apprendre à partir de données et à améliorer leurs performances au fil du temps, sans être explicitement programmées pour chaque tâche. Dans le domaine du génie civil, cette technologie trouve des applications de plus en plus larges, notamment dans la prédiction des propriétés des matériaux et l'optimisation des structures.

### 2.2.1 Machine Learning : historique et définition :

Les origines du machine learning remontent à 1959, lorsque le mathématicien américain Arthur Samuel a conçu un programme informatique capable d'apprendre à jouer aux dames de manière autonome, sans aucune intervention humaine. Il a alors introduit cette discipline comme étant l'ensemble des méthodes permettant aux machines d'acquérir des compétences sans avoir recours à une programmation explicite. Quelques décennies plus tard, en 1998, Tom Mitchell a affiné cette notion en stipulant qu'un système informatique est considéré comme apprenant lorsque ses résultats sur une tâche précise s'améliorent progressivement avec l'accumulation d'expériences. De manière générale, le machine learning peut donc être défini comme la faculté d'un système à identifier, par lui-même, la démarche de calcul la plus appropriée pour résoudre un problème donné [24].

Le machine learning constitue une branche fondamentale de l'intelligence artificielle, dont le principe repose sur la capacité des algorithmes à apprendre directement à partir d'un ensemble de données, plutôt que d'être programmés de manière conventionnelle. Cette approche permet de générer des modèles capables d'interpréter et d'analyser toute nouvelle donnée qui leur est soumise. Le ML trouve des applications dans de nombreux domaines, notamment la classification, le regroupement (clustering) et la régression. Sur le plan opérationnel, l'apprentissage automatique repose sur un processus itératif au cours duquel un algorithme ajuste et perfectionne son comportement au contact répété de bases de données, sans qu'un développeur n'intervienne directement, jusqu'à atteindre un niveau de performance satisfaisant [20, 24].

L'intégration du machine learning en génie civil représente une évolution significative qui transforme profondément les pratiques de ce domaine, en améliorant notamment la puissance de calcul numérique et la précision des résultats obtenus. Parmi ses nombreuses applications, on peut citer la prédiction des propriétés mécaniques des matériaux de construction, telle que la résistance à la compression du béton. Comme le montre la Figure 2.4, le fonctionnement du ML repose sur des algorithmes qui apprennent progressivement à partir des données disponibles et qui, une fois leurs hyperparamètres ajustés de manière appropriée, sont en mesure de fournir des prédictions fiables et très proches des données expérimentales réelles [20].



**Figure 2.1** : Schéma de fonctionnement de base de l'apprentissage automatique [20]

### 2.2.2 Différence entre ML et programmation classique :

Bien que la programmation classique ait longtemps dominé le développement logiciel, l'émergence du machine learning a introduit un nouveau paradigme dans le traitement de l'information. En effet, dans une approche classique, le comportement du système est entièrement défini par le développeur à travers un ensemble de règles explicites et figées. Le machine learning, quant à lui, adopte une logique inverse : plutôt que de suivre des instructions prédéfinies, le système apprend directement à partir des données et adapte son comportement en conséquence. Cette différence fondamentale de fonctionnement engendre des distinctions notables en termes de méthodologie, de gestion des données et de domaines d'application [25]. Le tableau suivant résume les principales différences entre ces deux approches :

**Tableau 2.1** : Analyse comparative entre la programmation classique et le machine learning

| Critère             | Programmation classique                                                                                                                                                                          | Machine Learning                                                                                                                                                                                                 |
|---------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Méthodologie        | <ul style="list-style-type: none"> <li>Le programmeur rédige manuellement les règles ; le système les applique aux données pour produire les résultats (données + règles = résultats)</li> </ul> | <ul style="list-style-type: none"> <li>On fournit au système les données et les résultats attendus ; la machine infère elle-même les règles sous-jacentes (données + résultats = règles)</li> </ul>              |
| Gestion des données | <ul style="list-style-type: none"> <li>Repose sur une logique conditionnelle « si... alors... » (If-Then), adaptée aux tâches régies par des règles fixes et explicites</li> </ul>               | <ul style="list-style-type: none"> <li>Excelle dans le traitement de volumes massifs de données non structurées (images, textes) pour lesquelles il est difficile de formuler des règles manuellement</li> </ul> |
| Adaptabilité        | <ul style="list-style-type: none"> <li>Le système ne s'adapte pas automatiquement ; toute modification nécessite l'intervention du programmeur</li> </ul>                                        | <ul style="list-style-type: none"> <li>Le modèle s'améliore automatiquement avec l'augmentation du volume de données, sans reprogrammation</li> </ul>                                                            |
| Transparence        | <ul style="list-style-type: none"> <li>Le comportement du système est entièrement explicable et traçable grâce aux règles définies</li> </ul>                                                    | <ul style="list-style-type: none"> <li>Les modèles complexes (ex. réseaux de neurones) peuvent être difficiles à interpréter (boîte noire)</li> </ul>                                                            |
| Applications        | <ul style="list-style-type: none"> <li>Logiciels comptables, sites web, systèmes de gestion de données traditionnels</li> </ul>                                                                  | <ul style="list-style-type: none"> <li>Reconnaissance faciale, conduite autonome, prévision météorologique, systèmes de recommandation</li> </ul>                                                                |

### 2.2.3 Types d'apprentissage

Le machine learning repose sur différents paradigmes d'apprentissage, adaptés selon la nature des données disponibles et les objectifs visés. On distingue principalement deux types :

#### 1. Apprentissage supervisé :

Dans ce type d'apprentissage, le modèle est entraîné à partir d'un ensemble de données étiquetées, c'est-à-dire que chaque exemple d'entrée est associé à une sortie connue. Le modèle s'ajuste en comparant le résultat qu'il produit avec la sortie attendue, et les paramètres sont modifiés de façon à minimiser l'écart entre les deux. Ce processus est répété de manière itérative jusqu'à ce qu'un critère de performance satisfaisant soit atteint [26].




Figure 2.2 : Schéma illustratif du processus d'apprentissage supervisé [27]

2. **Apprentissage non-supervisé** : L'apprentissage non supervisé consiste à détecter automatiquement des régularités au sein des données présentées, sans qu'aucune étiquette ne soit fournie. Le modèle identifie par lui-même les structures et les motifs cachés dans les données, en regroupant les exemples présentant des caractéristiques similaires. Les réseaux auto-organiseurs de Kohonen constituent l'un des exemples les plus connus de ce type d'apprentissage [22].




Figure 2.3 : Schéma illustratif du processus d'apprentissage non-supervisé [27]




## 2.3 Algorithmes de régression en Machine Learning

### 2.3.1 Analyse de régression :

L'analyse de régression constitue une famille de méthodes d'apprentissage automatique reposant sur la modélisation de la relation mathématique entre une variable dépendante  $Y$  et une ou plusieurs variables indépendantes  $X$ . Elle poursuit deux objectifs fondamentaux : la prédiction, qui vise à estimer des valeurs continues à partir de paramètres d'entrée mesurables, et l'inférence, qui permet d'identifier et de quantifier l'influence des différentes variables indépendantes sur la variable cible [20]. Selon la nature de la relation entre les variables, on distingue deux grandes catégories. La régression linéaire est utilisée lorsque cette relation est directe et proportionnelle, tandis que la régression non linéaire est privilégiée lorsque la

relation est plus complexe, ce qui est fréquemment le cas dans les applications réelles d'ingénierie [20]. Le tableau ci-dessous synthétise les principaux modèles de régression utilisés en machine learning, des approches statistiques classiques aux algorithmes les plus avancés :

**Tableau 2.2** : Principaux modèles de régression en machine learning [28, 29].

| Type de régression     | Définition                                                                                                                  | Fonction mathématique                     | Visualisation graphique                                                                                                                            |
|------------------------|-----------------------------------------------------------------------------------------------------------------------------|-------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------------------|
| Régression linéaire    | Modélise une relation proportionnelle et directe entre les variables d'entrée et la sortie via une droite ou un hyperplan.  | $Y = \beta_0 + \beta_1 X + \epsilon$      |  <p>Simple linear model</p> <p><math>y=b_0+b_1x</math></p>      |
| Régression polynomiale | Extension de la régression linéaire permettant de capturer des relations non linéaires en utilisant des puissances de $X$ . | $Y = \sum_{i=0}^n \beta_i X^i + \epsilon$ |  <p>Polynomial model</p> <p><math>y=b_0+b_1x+b_2x^2</math></p> |
| Régression logistique  | Utilisée pour prédire la probabilité d'appartenance à une classe (0 ou 1) via une fonction sigmoïde.                        | $P(Y = 1) = \frac{1}{1+e^{-z}}$           |  <p>Logistic Regression</p>                                   |


### 2.3.2 Machine à vecteurs de support (Support vector machine (SVM)) :

La machine à vecteurs de support est l'un des algorithmes les plus performants de l'apprentissage supervisé. Elle est largement employée pour les tâches de classification et de régression, et son principe fondamental repose sur la recherche de l'hyperplan optimal permettant de séparer les différentes classes de données avec une marge maximale [20, 23, 30]. Le fonctionnement de cet algorithme s'articule autour des concepts suivants :


- **Concept mathématique de la marge** : L'algorithme identifie les observations les plus proches de la frontière de décision, désignées sous le terme de vecteurs de support. La robustesse du modèle repose sur la maximisation de la distance entre ces vecteurs et l'hyperplan de séparation, ce qui confère au modèle une excellente capacité de généralisation et réduit le risque d'erreurs de classification lors du traitement de nouvelles données non vues lors de l'entraînement.

- **Astuce du noyau (Kernel Trick) :** Lorsque les données ne sont pas linéairement séparables dans l'espace d'entrée d'origine, les SVM recourent à des fonctions noyau pour projeter les données dans un espace de dimension supérieure, au sein duquel une séparation linéaire devient possible. Cette transformation facilite la modélisation des relations non linéaires complexes entre les variables d'entrée et les sorties du système.

L'algorithme SVM a démontré son efficacité dans la prédiction des propriétés mécaniques du béton. Il est notamment utilisé pour modéliser la relation entre les paramètres de composition et la résistance à la compression, se distinguant par sa précision satisfaisante même avec des jeux de données de taille limitée, comparativement aux architectures de réseaux de neurones profonds qui nécessitent généralement de grands volumes de données pour atteindre des performances optimales.



**Figure 2.4 :** Classificateur à machines à vecteurs de support (SVM) [31]




**Figure 2.5 :** Transfert des données vers un espace de dimension supérieure dans la machine à vecteurs de support (SVM) [31]

### 2.3.3 Random Forest (Forêt aléatoire)

L'algorithme Random Forest a été introduit par Leo Breiman en 2001 comme une méthode d'apprentissage supervisé de type ensemble, fondée sur la combinaison d'un grand nombre d'arbres de décision. Chaque arbre est construit à partir d'un sous-ensemble de données sélectionné aléatoirement, et la prédiction finale est obtenue par agrégation des résultats individuels ; par vote majoritaire dans le cas de la classification, et par calcul de la moyenne dans le cas de la régression. Cette stratégie collective permet d'atteindre un niveau de précision nettement supérieur à celui d'un arbre de décision isolé [2]. L'une des propriétés fondamentales de cet algorithme réside dans sa résistance au surapprentissage (overfitting). En effet, Breiman démontre mathématiquement que l'erreur de généralisation du modèle converge vers une valeur limite stable à mesure que le nombre d'arbres augmente, ce qui garantit la robustesse des prédictions même sur des données non vues lors de l'entraînement. Cette stabilité est assurée par l'introduction d'une double source d'aléatoire : d'une part, le tirage aléatoire avec remplacement des échantillons d'entraînement (bagging), et d'autre part, la sélection aléatoire d'un sous-ensemble de variables à chaque nœud de division, ce qui réduit la corrélation entre les arbres tout en maintenant leur précision individuelle [2].

Sur le plan des performances, Random Forest présente plusieurs avantages qui le distinguent des méthodes traditionnelles. Il se montre particulièrement robuste face aux données bruitées, s'adapte efficacement aux bases de données de grande dimensionnalité, et offre une estimation intégrée de l'importance relative de chaque variable d'entrée. Dans le domaine du génie civil, ces caractéristiques en font un outil

particulièrement adapté à la modélisation des propriétés mécaniques des matériaux de construction, notamment pour la prédiction de la résistance à la compression du béton à partir de paramètres de composition [2].



**Figure 2.6 :** Schéma du fonctionnement de l'algorithme Random Forest [2]

### 2.3.4 XGBoost (Extreme Gradient Boosting)

XGBoost (Extreme Gradient Boosting) est un algorithme d'apprentissage supervisé introduit par Chen et Guestrin en 2016, qui s'inscrit dans la catégorie des méthodes d'ensemble basées sur le renforcement par gradient (gradient boosting). Son fonctionnement repose sur une construction progressive d'arbres de décision, où chaque nouvel arbre est entraîné à corriger les erreurs résiduelles générées par les arbres précédents. À l'issue de ce processus itératif, les contributions de tous les arbres sont agrégées pour produire une prédiction finale robuste et précise [32]. Ce qui distingue XGBoost des algorithmes classiques de sa famille réside dans l'ensemble des optimisations techniques qu'il intègre. En effet, il dispose d'une gestion avancée des données incomplètes, d'une procédure de calcul des gains optimisée, ainsi que de mécanismes améliorés concernant la gestion de la mémoire, la réduction du volume des données et la distribution des calculs. Ces caractéristiques lui permettent de traiter efficacement de très larges volumes de données tout en limitant la consommation des ressources informatiques, ce qui le rend nettement plus performant que les solutions conventionnelles dans des contextes à grande échelle [32].

Ces atouts ont conduit à l'adoption de XGBoost dans un large éventail de domaines applicatifs, tels que la détection de transactions frauduleuses, l'analyse du risque financier et la modélisation climatique. Dans le contexte du génie civil, cet algorithme présente un intérêt particulier pour la prédiction des propriétés des matériaux de construction, grâce à sa capacité à fournir des résultats fiables même en présence de données hétérogènes ou incomplètes. Sa robustesse et son efficacité computationnelle en font aujourd'hui un outil incontournable tant dans les travaux de recherche que dans les applications à visée industrielle [32].




Figure 2.7 : Schéma de fonctionnement de l'algorithme XGBoost [32]

## 2.4 Deep Learning :

L'apprentissage profond est une branche avancée de l'apprentissage automatique, apparu dans le but de rapprocher les capacités des modèles informatiques de l'objectif ultime de l'intelligence artificielle : simuler la perception humaine. Cette technologie repose sur des architectures de réseaux de neurones multicouches inspirées de la structure biologique et fonctionnelle du cerveau, permettant aux systèmes d'acquérir plusieurs niveaux hiérarchiques de représentation, désignés sous le terme de Representation Learning, afin de modéliser les relations complexes et non linéaires présentes dans les données [33].




Figure 2.8 : Intelligence artificielle : du Machine Learning au Deep Learning [34].

La puissance analytique de l'apprentissage profond se manifeste à travers plusieurs caractéristiques fondamentales :

- **Représentation hiérarchique et abstraite** : La structure du Deep Learning repose sur le traitement de l'information à travers plusieurs couches cachées successives. Dans le contexte des matériaux de construction, les premières couches capturent des patterns simples tels que les

proportions des composants du mélange, tandis que les couches plus profondes extraient des concepts abstraits, comme l'effet des interactions microscopiques entre les granulats légers et la pâte de ciment sur la résistance finale [33].

- **Extraction automatique des caractéristiques :** Contrairement aux algorithmes d'apprentissage automatique classiques qui nécessitent une intervention manuelle pour sélectionner les variables pertinentes, ce que l'on appelle le Feature Engineering, l'apprentissage profond découvre automatiquement les caractéristiques les plus déterminantes à partir des données brutes. Cet avantage garantit une précision accrue face à l'hétérogénéité des propriétés du béton léger [20,23,33].
- **Mécanisme d'auto-optimisation et d'adaptation :** Les réseaux profonds fonctionnent par un processus itératif d'ajustement des poids et des biais via l'algorithme de rétropropagation du gradient (Backpropagation). Ce processus vise à minimiser la fonction de perte afin de réduire l'écart entre les valeurs expérimentales et les valeurs prédites, permettant au modèle de gagner en précision au fil des itérations [33].
- **Modélisation des relations non linéaires complexes :** Le béton léger se caractérise par des interactions non linéaires très complexes entre ses constituants. Grâce aux fonctions d'activation non linéaires intégrées dans chaque neurone artificiel, l'apprentissage profond est capable de modéliser ces interactions avec une précision supérieure à celle des modèles statistiques traditionnels [20,30,33].

#### 2.4.1 Applications en génie civil :

L'apprentissage profond offre aux ingénieurs des outils avancés pour améliorer les pratiques de conception et de construction, notamment dans trois domaines :

- **Prédiction de la résistance et de la durabilité :** ces modèles permettent d'estimer la résistance à la compression et le module d'élasticité avant le coulage réel, réduisant ainsi le recours aux essais de laboratoire coûteux [20,30].
- **Optimisation de la formulation :** les algorithmes aident à déterminer la combinaison optimale des composants pour obtenir un béton léger répondant aux exigences de résistance structurelle tout en minimisant la masse volumique [20,23].
- **Détection d'anomalies et contrôle qualité :** l'apprentissage profond permet de surveiller la qualité des mélanges en temps réel et de détecter les écarts par rapport aux normes ou la présence de défauts microscopiques avant l'exécution, contribuant ainsi à la sécurité des ouvrages [23].

#### 2.4.2 Réseaux de Neurones Artificiels :

Les réseaux de neurones artificiels sont des modèles de calcul avancés inspirés de la structure biologique du système nerveux central, conçus pour simuler la manière dont le cerveau humain traite l'information et acquiert des connaissances [22]. Leur force fondamentale réside dans leur capacité à apprendre à partir d'exemples et de données expérimentales antérieures, plutôt que de s'appuyer sur une programmation explicite de règles mathématiques. Cette propriété en fait un outil particulièrement adapté au traitement de problèmes caractérisés par la complexité et la non-linéarité [33]. La nature de leur fonctionnement peut être détaillée selon trois aspects fondamentaux :

- **Simulation biologique et modélisation mathématique :** Le réseau se compose d'unités de traitement élémentaires appelées neurones artificiels, qui correspondent fonctionnellement aux

cellules nerveuses du cerveau humain. Ces neurones sont interconnectés par des liaisons numériques pondérées appelées poids (Weights), qui déterminent l'influence de chaque variable d'entrée sur le résultat final et constituent la mémoire acquise par le modèle au cours de l'entraînement [33].

- **Traitement des données en génie civil :** Dans le contexte de l'étude des matériaux de construction, les réseaux de neurones artificiels fonctionnent comme une boîte noire intelligente, capable de découvrir les relations cachées entre les variables du béton, telles que l'effet du type de granulats légers et des adjuvants sur la porosité, sans recourir à des équations physiques explicites. Le réseau extrait implicitement la loi régissant le comportement du matériau en étant exposé de manière répétée aux données expérimentales de laboratoire [20,30].
- **Capacité de généralisation :** Le réseau ne se limite pas à la mémorisation des données d'entraînement, mais développe une capacité supérieure de généralisation, c'est-à-dire la prédiction des propriétés de nouveaux échantillons de béton qu'il n'a jamais rencontrés lors de la phase d'apprentissage. Cette propriété en fait un outil fiable pour estimer les performances du béton léger avant la phase d'exécution sur chantier, réduisant ainsi le recours aux essais expérimentaux coûteux [23].

#### 2.4.2.1 Architecture des réseaux de neurones artificiels :

Un réseau de neurones artificiels est structuré en trois types de couches organisées de manière séquentielle :

- **Couche d'entrée (Input Layer) :** elle reçoit les données brutes du problème, telles que les proportions des constituants du béton léger (dosage en ciment, rapport eau/liant, type et dosage des granulats légers, additions minérales, etc).
- **Couches cachées (Hidden Layers) :** elles constituent le cœur du traitement. Chaque couche extrait progressivement des représentations de plus en plus abstraites des données, en appliquant des transformations non linéaires à travers un ensemble de poids et de biais.
- **Couche de sortie (Output Layer) :** elle produit le résultat final du modèle, tel que la résistance à la compression, la masse volumique sèche ou le module d'élasticité.

L'architecture repose sur deux paramètres fondamentaux : les poids ( $w$ ), qui représentent la force de connexion entre les neurones et constituent la mémoire acquise lors de l'entraînement, et les biais ( $b$ ), qui permettent de décaler la fonction d'activation afin de garantir la flexibilité et l'adaptabilité du modèle. Dans le contexte du béton léger, les variables d'entrée ( $x$ ) correspondent aux paramètres de composition, tandis que les sorties ( $y$ ) représentent les propriétés mécaniques et physiques cibles [20].




Figure 2.9 : Architecture des réseaux de neurones artificiels [20]

#### 2.4.2.2 Fonctions d'activation :

La fonction d'activation détermine la sortie d'un neurone en fonction de la somme pondérée de ses entrées. Elle confère au réseau sa capacité à modéliser des relations non linéaires complexes. Les trois fonctions les plus utilisées dans ce contexte sont les suivantes [35] :

1. **Fonction ReLU (Rectified Linear Unit)** : Cette fonction a profondément transformé les pratiques de l'apprentissage profond en résolvant le problème de la disparition du gradient (Vanishing Gradient), permettant ainsi l'entraînement de réseaux de grande profondeur sans perte d'information. Sa formulation mathématique est :

$$f(x) = \max(0, x) \quad (2.1)$$





Figure 2.10 : Courbe de la fonction d'activation ReLU (Rectified Linear Unit) [35]

2. **Fonction sigmoïde** : Cette fonction est principalement utilisée dans la couche de sortie pour les tâches de classification binaire, car elle comprime la sortie dans l'intervalle  $[0, 1]$ , interprétable comme une probabilité. Sa formulation est [33] :


$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.2)$$



**Figure 2.11** : Courbe de la fonction d'activation sigmoïde [35]

3. **La fonction tangente hyperbolique (Tanh)** : Cette fonction constitue un choix particulièrement adapté pour les couches cachées des réseaux de neurones, car elle transforme les valeurs d'entrée dans l'intervalle  $[-1, 1]$ . Son principal avantage réside dans le fait qu'elle centre les sorties autour de zéro, ce qui facilite la convergence du processus d'apprentissage dans les couches suivantes et réduit le risque de saturation des gradients. Sa formulation mathématique est :

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.3)$$



**Figure 2.12 :** Courbe de la fonction d'activation Tangente Hyperbolique (Tanh) [35]


#### 2.4.2.3 Apprentissage d'un réseau de neurones artificiels :

Le processus d'entraînement d'un réseau de neurones se déroule en quatre étapes successives et interdépendantes :

1. **Propagation avant (Forward Propagation) :** Les données d'entrée se propagent de la couche d'entrée vers la couche de sortie. La sortie de chaque neurone est calculée selon l'équation suivante, avant application de la fonction d'activation [33] :

$$y = \sum (w_i * x_i) + b \quad (2.4)$$

Où  $w_i$  représente les poids,  $x_i$  les entrées, et  $b$  le biais.



**Figure 2.13 :** Principe de fonctionnement d'une fonction d'activation

2. **Calcul de la fonction de perte (Loss Function) :** La fonction de perte quantifie l'écart entre les valeurs prédites par le réseau ( $\hat{y}$ ) et les valeurs réelles mesurées expérimentalement ( $y$ ). Dans

les problèmes de prédiction des propriétés du béton, l'erreur quadratique moyenne (Mean Squared Error - MSE) est couramment utilisée :

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.5)$$

L'objectif de l'entraînement est de minimiser cette fonction, de sorte que les prédictions du modèle convergent vers la réalité physique du matériau [33].

3. **Rétropropagation (Backpropagation) :** L'algorithme de rétropropagation utilise la règle de dérivation en chaîne (Chain Rule) pour calculer la contribution de chaque poids à l'erreur totale. Les poids sont ensuite mis à jour selon l'équation suivante :

$$w_{new} = w_{old} - \eta * \frac{\partial loss}{\partial w} \quad (2.6)$$

où  $\eta$  désigne le taux d'apprentissage (Learning Rate), paramètre qui contrôle l'amplitude des mises à jour des poids à chaque itération [22].

4. **Optimisation des poids :** L'optimisation constitue le moteur du processus d'apprentissage. Elle repose sur l'algorithme de descente de gradient (Gradient Descent), qui ajuste de manière itérative les paramètres du réseau dans la direction opposée au gradient de la fonction de perte, afin d'atteindre un minimum global. La règle de mise à jour est la suivante :

$$\theta = \theta - \eta * \nabla_{\theta} J(\theta) \quad (2.7)$$

où  $\theta$  représente l'ensemble des paramètres du réseau,  $\eta$  le taux d'apprentissage, et  $\nabla_{\theta} J(\theta)$  le vecteur gradient indiquant la direction d'optimisation [22, 33].

## 2.5 Conclusion

Ce chapitre a permis d'établir les fondements théoriques nécessaires à la compréhension de l'intelligence artificielle et de l'apprentissage automatique. Après avoir retracé l'évolution historique de ce domaine et exposé les principes fondamentaux qui le sous-tendent, les différents paradigmes d'apprentissage ont été présentés, en distinguant l'apprentissage supervisé, non supervisé et par renforcement. Une attention particulière a été accordée aux architectures de réseaux de neurones artificiels, en détaillant leur structure, leurs fonctions d'activation et leur processus d'apprentissage par rétropropagation. Les principaux algorithmes retenus dans le cadre de ce travail ont également été décrits, à savoir la machine à vecteurs de support (SVM), la forêt aléatoire (Random Forest) et le XGBoost. Ces outils, reconnus pour leur capacité à modéliser des relations non linéaires complexes à partir de données multidimensionnelles hétérogènes, constituent le socle méthodologique sur lequel reposera le chapitre suivant, consacré à la mise en œuvre de ces modèles pour la prédiction des propriétés mécaniques et physiques des bétons légers.

Deuxième partie


**Partie Pratique**

## Chapitre 3

# Méthodologie et mise en œuvre des modèles d'apprentissage automatique

Ce chapitre présente la démarche méthodologique adoptée pour prédire les propriétés mécaniques et physiques des bétons légers à l'état durci. Le recours à l'intelligence artificielle se justifie par les limites inhérentes aux méthodes expérimentales classiques, lesquelles sont souvent coûteuses en temps et en ressources, et ne permettent pas une exploration systématique de l'espace des formulations. Les approches basées sur l'apprentissage automatique offrent, en revanche, une alternative plus rapide et plus précise pour la modélisation et l'optimisation des mélanges.

1. **Constitution de la base de données** : Collecte et compilation des résultats expérimentaux issus de la littérature scientifique, afin de constituer une base de données représentatif et suffisamment diversifié.
2. **Prétraitement des données** : Nettoyage de la base de données, traitement des valeurs manquantes et standardisation des variables, de manière à assurer des conditions d'apprentissage optimales pour les algorithmes.
3. **Modélisation** : Implémentation et entraînement de quatre modèles d'apprentissage automatique aux architectures distinctes : la Machine à Vecteurs de Support (SVM), les Réseaux de Neurones Artificiels (ANN), la Forêt Aléatoire (Random Forest) et le XGBoost.
4. **Évaluation des performances** : Comparaison des modèles à l'aide de métriques statistiques ( $R^2$ , RMSE) afin de sélectionner l'algorithme le plus performant pour chaque propriété cible du béton léger.



**Figure 3.1 :** Organigramme de la méthodologie de recherche pour la prédiction des propriétés du béton léger.

### 3.1 Travaux récents sur l'utilisation de l'IA pour les bétons légers :

Ces dernières années, l'application des algorithmes d'apprentissage automatique à la prédiction des propriétés des bétons légers a suscité un intérêt croissant dans la communauté scientifique. Plusieurs études ont démontré la capacité de ces approches à modéliser avec précision des relations complexes entre les paramètres de composition et les propriétés mécaniques et physiques du matériau. Le tableau 3.1 présente une synthèse des travaux les plus récents dans ce domaine.

**Tableau 3.1 :** Synthèse des travaux récents sur l'application du machine learning à la prédiction des propriétés des bétons légers

| N° | Algorithmes d'apprentissage automatique | Base de données | Paramètres d'entrée                                                                                                                                                                                                  | Paramètres de sortie        | Réf  |
|----|-----------------------------------------|-----------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------|------|
| 1  | SVM, ANN, DT, GPR, XGBoost              | 420             | Ciment, sable, rapport E/C, granulats naturels, cendres volantes, superplastifiant, temps de cure, quantité de granulat léger, densité de granulat léger, absorption d'eau de granulat léger, type de granulat léger | Résistance à la compression | [20] |

|   |                                                         |     |                                                                                                                                                                                                    |                                                                                                                             |       |
|---|---------------------------------------------------------|-----|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------|-------|
| 2 | <b>RNA</b> (Réseaux de Neurones Artificiels)            | 149 | Densité, Eau, Rapport E/L, Ciment, Cendres volantes, Fumée de silice, Granulats légers fins, Granulats légers gros, Granulats naturels fins, Granulats naturels courants                           | Résistance à la compression, Module d'élasticité                                                                            | [36]  |
| 3 | Deep Neural Networks (DNN), Ensemble Regression Trees   | 100 | Ciment, eau, granulats légers, fibres d'acier, fibres de polypropylène, superplastifiant                                                                                                           | Résistance à la compression (cubique et prismatique), résistance à la traction par flexion, résistance à la traction axiale | [37]  |
| 4 | GPR optimisé, SVMR optimisé, EL optimisé, GPR, SVMR, EL | 240 | Ciment, granulats légers, sable, Eau, cendres volantes, fumée de silice, superplastifiant                                                                                                          | Résistance à la compression                                                                                                 | [21]  |
| 5 | <b>RNA</b> (Réseaux de Neurones Artificiels)            | 35  | Densité, résistance à la compression, Résistance à la flexion, Module d'élasticité                                                                                                                 | Coefficient de Poisson                                                                                                      | [ 30] |
| 6 | <b>RNA</b> (Réseaux de Neurones Artificiels)            | 147 | Ciment, rapport E/C, gravillons de briques, gravillons de tuiles, agrégats naturels                                                                                                                | Résistance à la compression à 28 jours                                                                                      | [38]  |
| 7 | <b>RNA</b> (Réseaux de Neurones Artificiels)            | 640 | Densité théorique, densité des grains, temps de mise en place, temps de vibration, densité sèche de l'éprouvette, vitesse d'onde longitudinale ( $V_p$ ), indice de ségrégation basé sur les ondes | Résistance à la compression                                                                                                 | [39]  |

### 3.2 Description de la base de données :

La fiabilité d'un modèle d'apprentissage automatique dépend intrinsèquement de la qualité et de la représentativité des données d'entraînement. Dans le cadre de ce travail, quatre bases de données distinctes ont été constituées à partir de travaux expérimentaux issus de la littérature scientifique internationale indexée, chacune dédiée à la prédiction d'une propriété spécifique du béton léger à l'état durci. Ces bases

sont présentées de manière synthétique dans le Tableau 1, qui précise pour chacune le paramètre de sortie visé, le nombre d'essais disponibles ainsi que les références bibliographiques correspondantes. Les variables d'entrée sont communes aux quatre bases et comprennent douze paramètres représentatifs de la composition du béton léger, regroupés en trois catégories : les constituants de base ; ciment ( $\text{kg}/\text{m}^3$ ), rapport eau/liant ( $E/L$ ), sable ( $\text{kg}/\text{m}^3$ ) et granulats ordinaires ( $\text{kg}/\text{m}^3$ ), les caractéristiques des granulats légers ; granulats légers type 1 et type 2 ( $\text{kg}/\text{m}^3$ ) ainsi que leurs densités apparentes respectives ; et enfin les additions et adjuvants ; superplastifiant ( $\text{kg}/\text{m}^3$ ), cendres volantes ( $\text{kg}/\text{m}^3$ ), fumée de silice ( $\text{kg}/\text{m}^3$ ) et autre addition minérale ( $\text{kg}/\text{m}^3$ ). Les variables de sortie correspondent aux quatre propriétés cibles : la résistance à la compression à 28 jours (MPa), la résistance à la traction à 28 jours (MPa), la masse volumique sèche ( $\text{kg}/\text{m}^3$ ) et le module d'élasticité (GPa).

**Tableau 3.2 :** Description des quatre bases de données utilisées

| N° | Base de données             | Paramètres d'entrée                                                                                                                                                                                                       | Paramètre de sortie                     | Nombre d'essais | Références                                                                                                          |
|----|-----------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------|-----------------|---------------------------------------------------------------------------------------------------------------------|
| 1  | Résistance à la compression | Ciment, $E/L$ , Sable, Granulats ordinaires, Granulats légers type 1, Granulats légers type 2, Superplastifiant, Densité apparente GL1, Densité apparente GL2, Cendres volantes, Fumée de silice, Autre addition minérale | Résistance à la compression à 28j (MPa) | 589             | [40–103]                                                                                                            |
| 2  | Résistance à la traction    | Ciment, $E/L$ , Sable, Granulats ordinaires, Granulats légers type 1, Granulats légers type 2, Superplastifiant, Densité apparente GL1, Densité apparente GL2, Cendres volantes, Fumée de silice, Autre addition minérale | Résistance à la traction à 28j (MPa)    | 285             | [42, 43, 45, 47, 50, 51, 53, 54, 56, 59, 61, 63, 68, 69, 71–73, 76–82, 84, 86–88, 90, 91, 94, 96, 98, 99, 101, 102] |

|   |                       |                                                                                                                                                                                                                        |                                            |     |                                                             |
|---|-----------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------|-----|-------------------------------------------------------------|
| 3 | Masse volumique sèche | Ciment, E/L, Sable, Granulats ordinaires, Granulats légers type 1, Granulats légers type 2, Superplastifiant, Densité apparente GL1, Densité apparente GL2, Cendres volantes, Fumée de silice, Autre addition minérale | Masse volumique sèche (kg/m <sup>3</sup> ) | 439 | [41,42,45–47,49,51–103]                                     |
| 4 | Module d'élasticité   | Ciment, E/L, Sable, Granulats ordinaires, Granulats légers type 1, Granulats légers type 2, Superplastifiant, Densité apparente GL1, Densité apparente GL2, Cendres volantes, Fumée de silice, Autre addition minérale | Module d'élasticité (GPa)                  | 288 | [47,48,50–56,59–65,70,73,74,76–79,81–83,86,88,90,96–98,102] |

### 3.3 Analyse exploratoire des données :

#### 3.3.1 Statistiques descriptives :

Avant l'application des algorithmes d'apprentissage automatique, une analyse descriptive préliminaire est conduite afin de caractériser les propriétés statistiques de la base de données. Cette analyse a été réalisée à l'aide du langage de programmation Python sous l'environnement Google Colaboratory (Google Colab), une plateforme en ligne gratuite permettant l'exécution de code Python sans installation locale. Elle permet d'évaluer, pour chaque paramètre, le nombre de valeurs disponibles, le nombre de valeurs manquantes, ainsi que les indicateurs de dispersion : valeurs maximale et minimale, moyenne et écart-type. Cette étape est essentielle pour évaluer la qualité et l'homogénéité des données avant la phase de modélisation, et pour détecter d'éventuelles anomalies susceptibles d'affecter les performances des modèles.

#### 3.3.2 Analyse des corrélations entre variables :

La matrice de corrélation constitue un outil d'analyse exploratoire indispensable pour quantifier les relations linéaires entre les variables d'entrée et les propriétés cibles. Cette analyse a été réalisée à l'aide du langage de programmation Python sous l'environnement Google Colaboratory (Google Colab), en utilisant la bibliothèque Seaborn pour la visualisation et la bibliothèque Pandas pour le calcul des coefficients. L'examen des coefficients de corrélation de Pearson permet d'identifier les paramètres les plus influents sur les performances du béton.

léger. Une valeur proche de  $+1$  ou de  $-1$  traduit une dépendance linéaire forte, tandis qu'une valeur proche de  $0$  indique une absence de relation linéaire entre les variables concernées. Cette analyse justifie scientifiquement la sélection des variables d'entrée et prépare les algorithmes à modéliser les interactions complexes lors de la phase d'apprentissage [104]. Le coefficient de corrélation de Pearson est calculé selon la formule suivante :

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \times \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (3.1)$$

où  $x_i$  et  $y_i$  représentent les valeurs des deux variables,  $\bar{x}$  et  $\bar{y}$  leurs moyennes respectives, et  $n$  le nombre d'observations.

### 3.4 Prétraitement des données :

Avant toute modélisation, les données brutes doivent subir une série de transformations visant à garantir leur qualité et leur cohérence. En effet, des données incomplètes, erronées ou hétérogènes peuvent compromettre significativement les performances des algorithmes d'apprentissage automatique et conduire à des prédictions peu fiables.

La première opération consiste à détecter les valeurs manquantes au sein de la base de données. Lorsque de telles lacunes sont identifiées, une interpolation linéaire est appliquée afin de reconstituer les données absentes tout en préservant la continuité et la cohérence de l'ensemble du jeu de données. Dans un second temps, les valeurs aberrantes ; c'est-à-dire les observations qui s'écartent de manière anormale de la distribution générale ; sont repérées et corrigées, afin d'éviter qu'elles n'introduisent un biais lors de la phase d'apprentissage.

Par la suite, une analyse de corrélation basée sur le coefficient de Pearson est conduite pour évaluer le degré de liaison entre chaque variable d'entrée et les propriétés mécaniques cibles. Cette démarche permet non seulement d'identifier les paramètres les plus déterminants, mais également d'éliminer les variables redondantes susceptibles de nuire à la stabilité des modèles.

Enfin, une étape de normalisation est appliquée à l'ensemble des variables d'entrée afin de les ramener à une échelle commune. En l'absence de cette mise à l'échelle, les variables à forte amplitude risquent de dominer les variables à faible amplitude, introduisant ainsi des biais dans le processus d'apprentissage. Cette opération est particulièrement indispensable pour les modèles sensibles aux différences d'échelle, tels que les ANN et le SVM. La méthode Min-Max (Min-Max-Scaler) a été retenue, ramenant les valeurs de chaque variable dans l'intervalle  $[0, 1]$  selon la formule suivante [20] :

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3.2)$$

Les paramètres de normalisation ont été calculés exclusivement sur l'ensemble d'entraînement, puis appliqués aux ensembles de validation et de test, afin d'éviter toute fuite d'information (Data Leakage).

Le tableau ci-après récapitule, pour chaque base de données, le nombre d'échantillons avant et après la phase de prétraitement, permettant ainsi d'évaluer l'impact des opérations de nettoyage et de correction sur la taille effective de la base de données utilisée pour la modélisation.

**Tableau 3.3** : Récapitulatif des échantillons avant et après prétraitement pour chaque base de données

| Base de données             | Nombre d'essais avant prétraitement | Nombre d'essais après prétraitement |
|-----------------------------|-------------------------------------|-------------------------------------|
| Résistance à la compression | 589                                 | 571                                 |
| Résistance à la traction    | 287                                 | 285                                 |
| Masse volumique sèche       | 439                                 | 428                                 |
| Module d'élasticité         | 288                                 | 284                                 |

### 3.5 Modèles d'apprentissage automatique utilisés :

Dans le cadre de ce travail, quatre algorithmes d'apprentissage automatique ont été sélectionnés pour modéliser les propriétés mécaniques et physiques des bétons légers. L'ensemble de la modélisation a été réalisé à l'aide du langage de programmation Python sous l'environnement Google Colaboratory (Google Colab), en exploitant les bibliothèques spécialisées Scikit-learn, TensorFlow et XGBoost. Ce choix repose sur la complémentarité de ces approches et leur capacité à traiter des données hétérogènes issues de formulations variées. Les réseaux de neurones artificiels (ANN) sont retenus pour leur aptitude à modéliser des relations non linéaires complexes entre les paramètres de composition et les propriétés cibles. La machine à vecteurs de support (SVM) est intégrée pour sa capacité à traiter efficacement des problèmes de régression dans des espaces de grande dimension, tout en offrant une bonne généralisation grâce à la maximisation de la marge de séparation. La forêt aléatoire (Random Forest) est choisie pour sa capacité à gérer des variables d'entrée hétérogènes et sa résistance naturelle au bruit présent dans les données. Enfin, le XGBoost est adopté pour ses performances élevées en termes de précision de prédiction et d'optimisation, grâce à son mécanisme d'apprentissage par boosting par gradient. Cette approche comparative, mobilisant quatre architectures aux principes distincts, vise à identifier le modèle le plus performant pour chaque propriété cible du béton léger.

#### 3.5.1 Réseaux neuronaux artificiels (RNA) :

Les réseaux de neurones artificiels constituent des outils performants pour modéliser les relations non linéaires complexes entre les paramètres de composition du béton, tels que le rapport eau/liant, les dosages en granulats et en additions minérales et ses propriétés mécaniques et physiques à l'état durci, notamment la résistance et la masse volumique. La méthodologie adoptée repose sur une division rigoureuse et uniforme de la base de données pour les quatre propriétés étudiées (MVB, RC, ME et RT). Conformément aux exigences méthodologiques visant à prévenir le sur-apprentissage et à garantir la fiabilité des prédictions, chaque base de données a été répartie selon les proportions suivantes :

- a. **Ensemble d'entraînement (70 %)** : utilisé pour l'ajustement des poids du modèle et la capture des corrélations entre les variables d'entrée et les propriétés cibles.
- b. **Ensemble de validation (15 %)** : dédié au réglage des hyperparamètres, nombre de couches, nombre de neurones et fonction d'activation, ainsi qu'à la surveillance du processus d'apprentissage.
- c. **Ensemble de test (15 %)** : réservé à l'évaluation finale des performances du modèle sur des données non utilisées lors de l'entraînement.

Cette répartition fixe (70/15/15) a été appliquée de manière systématique à chaque propriété, afin d'assurer la cohérence et la comparabilité des résultats entre les différents modèles développés. La performance de ces modèles a nécessité un réglage précis de l'architecture (en termes de nombre de couches cachées et de neurones) propre

à chaque propriété cible, garantissant ainsi une capacité de généralisation optimale. Les réseaux de neurones artificiels de type Perceptron Multicouche (MLP) ont été mis en œuvre pour modéliser les relations complexes entre les paramètres de composition et les propriétés mécaniques et physiques des bétons légers. Les modèles développés reposent sur l'algorithme d'optimisation Adam, avec un taux d'apprentissage fixé à 0,001, reconnu pour sa convergence rapide et sa stabilité lors de l'entraînement. Préalablement à la phase d'apprentissage, les données d'entrée ont été normalisées par standardisation (StandardScaler), afin de centrer et réduire chaque variable et ainsi garantir la stabilité numérique et la cohérence des performances du modèle. Les architectures des modèles ANN ont été adaptées à chaque propriété cible afin d'optimiser les performances de prédiction.

1. Le modèle dédié à la masse volumique (MV) repose sur une architecture séquentielle à trois couches cachées, avec une distribution de neurones de (64, 128, 64). Sa conception relativement simple est justifiée par la nature moins complexe des relations liant les paramètres de composition à cette propriété.
2. Les modèles de la résistance à la compression (RC) et du module d'élasticité (ME) partagent une architecture plus profonde à quatre couches cachées, avec une distribution de neurones de (128, 256, 128, 64).
3. Le modèle de la résistance à la traction (RT) adopte une architecture intermédiaire à trois couches cachées, avec une distribution de neurones de (128, 64, 32).

Pour l'ensemble des modèles, la fonction d'activation ReLU est utilisée dans les couches cachées pour modéliser les relations non linéaires, tandis que la couche de sortie adopte une fonction linéaire, adaptée aux tâches de régression.

### 3.5.2 Forêt Aléatoire (Random Forest) :

La forêt aléatoire est un algorithme d'apprentissage par ensemble qui construit plusieurs arbres de décision indépendants sur des sous-échantillons aléatoires des données, puis agrège leurs prédictions afin de réduire la variance et d'améliorer la robustesse du modèle. Comparativement aux réseaux de neurones artificiels, cet algorithme présente l'avantage d'être naturellement résistant au bruit et peu sensible aux différences d'échelle entre variables.

Dans le cadre de ce travail, le modèle Random Forest a été appliqué à la prédiction des quatre propriétés cibles : la résistance à la compression (RC), la résistance à la traction (RT), la masse volumique sèche (MVB) et le module d'élasticité (ME). La répartition des données adoptée est identique à celle utilisée pour les autres modèles, soit 70 % pour l'entraînement, 15 % pour la validation et 15 % pour le test.

Le modèle a été configuré avec un nombre d'arbres fixé à 500, afin d'assurer la stabilité et la cohérence des prédictions. La profondeur maximale de chaque arbre (`max_depth`) a été limitée à 15, permettant au modèle de capturer les interactions complexes entre les constituants du béton léger tout en prévenant le surapprentissage. Les paramètres `min_samples_split` et `min_samples_leaf` ont été respectivement fixés à 2 et 1, assurant une segmentation suffisamment fine des nœuds de décision. Enfin, une graine aléatoire fixe (`random_state = 42`) a été définie afin de garantir la reproductibilité des résultats.

### 3.5.3 XGBoost (Gradient Boosting) :

Le XGBoost est un algorithme d'apprentissage par boosting par gradient qui repose sur la construction séquentielle d'arbres de décision, chaque arbre étant entraîné à corriger les erreurs résiduelles du modèle précédent. Cette approche itérative permet d'atteindre des niveaux de précision élevés tout en maintenant une vitesse de calcul remarquable, ce qui en fait l'un des algorithmes les plus performants pour la modélisation de données tabulaires complexes et hétérogènes [105].

Le modèle XGBoost a été mis en œuvre pour la prédiction des quatre propriétés cibles du béton léger, à savoir la résistance à la compression (RC), la résistance à la traction (RT), la masse volumique sèche (MVB) et le module d'élasticité (ME). Conformément à la stratégie de partitionnement adoptée pour l'ensemble des modèles développés dans ce travail, la base de données a été répartie selon les proportions 70/15/15, correspondant respectivement aux ensembles d'entraînement, de validation et de test. Le modèle a été configuré avec 1000 arbres et un taux d'apprentissage (`learning_rate`) de 0,05, favorisant une correction progressive et contrôlée des erreurs résiduelles à chaque itération. La profondeur maximale des arbres (`max_depth`) a été fixée à 6, assurant un

équilibre satisfaisant entre la capacité d'apprentissage du modèle et sa faculté de généralisation sur des données non utilisées lors de l'entraînement. Afin de renforcer la robustesse du modèle et de prévenir le surapprentissage, un échantillonnage partiel a été appliqué, avec un taux de sous-échantillonnage des observations (subsample) et des variables (colsample\_bytree) tous deux fixés à 0,8. Enfin, une graine aléatoire fixe (random\_state = 42) a été définie pour assurer la reproductibilité des résultats.

### 3.5.4 Machine à vecteurs de support (SVM) :

La machine à vecteurs de support appliquée à la régression (SVR) détermine la fonction de prédiction optimale en maximisant la marge de tolérance autour des valeurs observées. Grâce à l'utilisation de fonctions noyau, elle est capable de modéliser des relations non linéaires complexes en projetant les données dans un espace de dimension supérieure. Ses performances dépendent toutefois d'une normalisation rigoureuse des données et d'un réglage précis des hyperparamètres [31].

Le modèle SVR a été appliqué à la prédiction des quatre propriétés cibles du béton léger, à savoir la résistance à la compression (RC), la résistance à la traction (RT), la masse volumique sèche (MVB) et le module d'élasticité (ME). La base de données a été partitionnée selon les mêmes proportions que celles adoptées pour les autres modèles, soit 70 % pour l'entraînement, 15 % pour la validation et 15 % pour le test. Les données d'entrée ont été préalablement normalisées par standardisation (StandardScaler) afin de garantir des conditions d'apprentissage optimales, le modèle SVR étant particulièrement sensible aux différences d'échelle entre variables. Un noyau à fonction de base radiale (RBF) a été retenu pour sa capacité à modéliser les relations non linéaires complexes entre les paramètres de composition du béton léger et ses propriétés mécaniques et physiques. Le paramètre de régularisation a été fixé à  $C = 100$ , le seuil d'insensibilité à  $\gamma = 0,01$ , et le coefficient gamma défini sur la valeur automatique « scale », permettant au modèle de s'adapter automatiquement à la variance des données d'entrée. Cette configuration assure un équilibre satisfaisant entre la précision de prédiction et la capacité de généralisation sur des données non vues lors de l'entraînement.

## 3.6 Métriques statistiques d'évaluation des modèles développés :

Afin d'évaluer et de comparer les performances des modèles d'apprentissage automatique développés dans ce travail, deux indicateurs statistiques complémentaires ont été retenus : le coefficient de détermination ( $R^2$ ) et l'erreur quadratique moyenne (RMSE) :

- Le coefficient de détermination  $R^2$  quantifie la proportion de la variance des valeurs cibles expliquée par le modèle. Sa valeur est comprise entre 0 et 1 : plus elle se rapproche de 1, plus le modèle reproduit fidèlement les observations expérimentales, traduisant ainsi une précision de prédiction élevée.
- L'erreur quadratique moyenne RMSE mesure l'écart moyen entre les valeurs prédites et les valeurs réelles, en pénalisant davantage les erreurs importantes. Plus sa valeur est faible, plus les prédictions du modèle convergent vers la droite de régression et se rapprochent des résultats expérimentaux.

Les formulations mathématiques de ces deux indicateurs sont présentées ci-après [20] :

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (k_{act} - k_{pre})^2} \quad (3.3)$$

$$R^2 = 1 - \frac{\sum (k_{act} - \bar{k}_{pre})^2}{\sum (k_{act} - \bar{k}_{pre})^2} \quad (3.4)$$

où  $K_{pre}$  et  $K_{act}$  représentent respectivement les valeurs prédites par le modèle et les valeurs mesurées expérimentalement ;  $m$  désigne le nombre total d'observations, et  $\bar{K}_{pre}$  correspond à la moyenne des valeurs prédites.

### 3.7 Conclusion :

Ce chapitre a présenté la démarche méthodologique complète mise en œuvre pour la prédiction des propriétés mécaniques et physiques des bétons légers par apprentissage automatique. Cette démarche s'est articulée autour de quatre étapes séquentielles : la constitution de quatre bases de données à partir de la littérature scientifique internationale, le prétraitement des données incluant le traitement des valeurs manquantes, la détection des valeurs aberrantes, l'analyse de corrélation et la normalisation, la modélisation par quatre algorithmes d'apprentissage automatique aux architectures complémentaires, et enfin l'évaluation des performances à l'aide de métriques statistiques standardisées. Le choix des quatre modèles, ANN, SVM, Random Forest et XGBoost, repose sur leur complémentarité algorithmique. Les ANN excellent dans la capture des relations non linéaires complexes, le SVM offre une bonne généralisation sur des données de taille limitée, le Random Forest assure une robustesse face aux données hétérogènes et bruitées, tandis que le XGBoost se distingue par ses performances élevées grâce à son mécanisme de boosting par gradient. Les résultats issus de cette méthodologie seront analysés et discutés dans le chapitre suivant, où les performances de chaque modèle seront comparées et interprétées pour chaque propriété cible, afin de valider la pertinence et l'efficacité de l'approche proposée.

## Chapitre 4

# Résultats et Analyse des Modèles de Prédiction

Ce chapitre est consacré à l'évaluation et à la comparaison des performances prédictives de plusieurs modèles d'apprentissage automatique appliqués aux propriétés mécaniques du béton léger à l'état durci. Les propriétés ciblées sont la résistance à la compression, la résistance à la traction, le module d'élasticité et la masse volumique.

Les modèles étudiés ont été entraînés et évalués sur la base de données expérimentales constituée au chapitre précédent, organisée selon une répartition de 70 % pour l'entraînement, et 15 % pour le test. Cette répartition garantit une évaluation objective des capacités de généralisation de chaque modèle sur des données non vues lors de la phase d'apprentissage.

Afin de comparer rigoureusement les performances des modèles, deux métriques d'évaluation ont été retenues : le coefficient de détermination ( $R^2$ ), qui mesure la qualité de l'ajustement entre les valeurs prédites et les valeurs réelles, et l'erreur quadratique moyenne (RMSE), qui quantifie l'écart moyen entre les prédictions et les observations.

L'objectif principal est d'identifier l'algorithme offrant la meilleure précision et la meilleure robustesse parmi les quatre modèles retenus : les Réseaux de Neurones Artificiels (ANN), la Forêt Aléatoire (Random Forest), le Gradient Boosting Extrême (XGBoost) et les Machines à Vecteurs de Support (SVM). Ce chapitre est organisé de manière à présenter successivement les résultats obtenus pour chaque propriété mécanique, suivis d'une comparaison globale des modèles permettant de dégager les conclusions les plus pertinentes pour l'optimisation des formulations du béton léger.

### 4.1 Analyse descriptive des données :

#### 4.1.1 Distribution des variables d'entrée et des propriétés cibles :

Avant d'entamer la phase de modélisation, une analyse exploratoire approfondie a été conduite sur la base de données expérimentale constituée. Les tableaux 4.1, 4.2, 4.3 et 4.4 présentent les caractéristiques statistiques descriptives de l'ensemble des variables d'entrée et des propriétés cibles pour chacun des quatre modèles de prédiction. L'absence totale de valeurs manquantes dans l'ensemble des variables confirme la qualité et la complétude de la base de données utilisée.

Les variables d'entrée retenues pour la modélisation sont au nombre de douze : le dosage en ciment ( $\text{kg}/\text{m}^3$ ), le rapport eau/liant (E/L), le dosage en sable ( $\text{kg}/\text{m}^3$ ), les granulats ordinaires ( $\text{kg}/\text{m}^3$ ), les granulats légers de type 1 ( $\text{kg}/\text{m}^3$ ), les granulats légers de type 2 ( $\text{kg}/\text{m}^3$ ), le superplastifiant ( $\text{kg}/\text{m}^3$ ), la densité apparente des granulats légers de type 1, la densité apparente des granulats légers de type 2, les additions minérales sous forme de cendres volantes ( $\text{kg}/\text{m}^3$ ), de fumée de silice ( $\text{kg}/\text{m}^3$ ) et d'autres additifs minéraux ( $\text{kg}/\text{m}^3$ ).

L'examen des tableaux statistiques révèle une grande diversité dans les plages de variation des variables d'entrée. Les statistiques varient selon la base de données considérée. Pour la base RC (589 essais), le dosage en

ciment varie entre 0 et 1550 kg/m<sup>3</sup> avec une moyenne de 430,11 kg/m<sup>3</sup> et un écart-type de 197,82 kg/m<sup>3</sup>, reflétant la large gamme de formulations collectées dans la littérature. Le rapport E/L oscille entre 0,103 et 1,88 avec une moyenne de 0,414. Les granulats légers de type 1 et de type 2 présentent des écarts-types élevés, respectivement 262,9 et 182,71 kg/m<sup>3</sup>, traduisant une forte variabilité dans les proportions utilisées selon les études collectées. Les cendres volantes et la fumée de silice présentent des moyennes relativement faibles, respectivement 31,20 et 4,797 kg/m<sup>3</sup>, avec des valeurs maximales de 381,70 et 92,00 kg/m<sup>3</sup>, indiquant que ces additions ne sont présentes que dans une partie des formulations.

Quant aux propriétés cibles, leurs plages de variation sont également très étendues, témoignant de la diversité des bétons légers représentés dans les quatre bases de données :

- Résistance à la compression (RC), 589 essais : varie entre 0 et 72,44 MPa avec une moyenne de 27,60 MPa et un écart-type de 17,12 MPa.
- Module d'élasticité (ME) , 288 essais : varie entre 2,00 et 48,68 GPa avec une moyenne de 17,89 GPa et un écart-type de 9,04 GPa.
- Masse volumique du béton durci (MVB) , 439 essais : varie entre 612 et 2459 kg/m<sup>3</sup> avec une moyenne de 1577,4 kg/m<sup>3</sup> et un écart-type de 379,3 kg/m<sup>3</sup>.
- Résistance à la traction (RT) , 285 essais : varie entre 0,37 et 6,15 MPa avec une moyenne de 2,59 MPa et un écart-type de 1,03 MPa.

Cette diversité des valeurs confirme la représentativité de la base de données pour l'entraînement et l'évaluation des modèles d'apprentissage automatique.

**Tableau 4.1** : Caractéristiques statistiques des variables d'entrée et de la propriété cible 'MVB'

| Paramètre               | N   | Manquantes | Moyenne | Ecart-type | Min    | Max    | Type   |
|-------------------------|-----|------------|---------|------------|--------|--------|--------|
| Ciment                  | 439 | 0          | 439.9   | 213.5      | 137.9  | 1550.0 | entrée |
| E/L                     | 439 | 0          | 0.4231  | 0.0956     | 0.1030 | 0.8000 | entrée |
| Sable                   | 439 | 0          | 545.2   | 437.8      | 0.0    | 3100.0 | entrée |
| Granulats ordinaires    | 439 | 0          | 179.2   | 571.8      | 0.0    | 3284.0 | entrée |
| Granulats légers type 1 | 439 | 0          | 295.0   | 270.1      | 0.0    | 1275.0 | entrée |
| Granulats légers type 2 | 439 | 0          | 82.81   | 157.39     | 0.00   | 830.00 | entrée |
| Superplastifiant        | 439 | 0          | 2.455   | 3.738      | 0.000  | 18.000 | entrée |
| Densité app. GL1        | 439 | 0          | 1065.4  | 602.1      | 0.0    | 2240.0 | entrée |
| Densité app. GL2        | 288 | 0          | 378.4   | 570.7      | 0.0    | 1860.0 | entrée |
| Cendres volantes        | 439 | 0          | 25.57   | 68.34      | 0.00   | 381.70 | entrée |
| Fumée de silice         | 439 | 0          | 5.408   | 16.278     | 0.000  | 92.000 | entrée |
| Autres additifs         | 439 | 0          | 12.42   | 38.43      | 0.00   | 310.00 | entrée |
| MVB du béton            | 439 | 0          | 1577.4  | 379.3      | 612.0  | 2459.0 | sortie |

**Tableau 4.2 :** Caractéristiques statistiques des variables d'entrée et de la propriété cible 'Module d'élasticité (ME)'

| Paramètre               | N   | Manquantes | Moyenne | Ecart-type | Min    | Max     | Type   |
|-------------------------|-----|------------|---------|------------|--------|---------|--------|
| Ciment                  | 288 | 0          | 418.00  | 115.55     | 171.00 | 710.00  | entrée |
| E/L                     | 288 | 0          | 0.4001  | 0.0963     | 0.2340 | 0.8000  | entrée |
| Sable                   | 288 | 0          | 622.2   | 312.6      | 0.0    | 1360.0  | entrée |
| Granulats ordinaires    | 288 | 0          | 149.7   | 308.1      | 0.0    | 1593.0  | entrée |
| Granulats légers type 1 | 288 | 0          | 342.3   | 238.4      | 0.0    | 1131.0  | entrée |
| Granulats légers type 2 | 288 | 0          | 98.27   | 166.55     | 0.00   | 830.00  | entrée |
| Superplastifiant        | 288 | 0          | 4.419   | 13.190     | 0.000  | 218.000 | entrée |
| Densité app. GL1        | 288 | 0          | 916.8   | 472.7      | 0.0    | 1890.0  | entrée |
| Densité app. GL2        | 288 | 0          | 523.8   | 665.7      | 0.0    | 1860.0  | entrée |
| Cendres volantes        | 288 | 0          | 30.02   | 55.75      | 0.00   | 300.00  | entrée |
| Fumée de silice         | 288 | 0          | 4.410   | 14.509     | 0.000  | 71.000  | entrée |
| Autres additifs         | 288 | 0          | 7.79    | 29.74      | 0.00   | 330.00  | entrée |
| Module d'élasticité     | 288 | 0          | 17.890  | 9.044      | 2.000  | 48.680  | sortie |

**Tableau 4.3 :** Caractéristiques statistiques des variables d'entrée et de la propriété cible 'Résistance à la compression (RC)'


| Paramètre                   | N   | Manquantes | Moyenne | Ecart-type | Min    | Max     | Type   |
|-----------------------------|-----|------------|---------|------------|--------|---------|--------|
| Ciment                      | 589 | 0          | 430.11  | 197.82     | 0.00   | 1550.00 | entrée |
| E/L                         | 589 | 0          | 0.4143  | 0.1102     | 0.1030 | 1.8800  | entrée |
| Sable                       | 589 | 0          | 598.3   | 400.7      | 0.0    | 3100.0  | entrée |
| Granulats ordinaires        | 589 | 0          | 182.7   | 518.7      | 0.0    | 3284.0  | entrée |
| Granulats légers type 1     | 589 | 0          | 303.4   | 262.9      | 0.0    | 1275.0  | entrée |
| Granulats légers type 2     | 589 | 0          | 74.98   | 182.71     | 0.00   | 2631.00 | entrée |
| Superplastifiant            | 589 | 0          | 3.251   | 9.879      | 0.000  | 218.000 | entrée |
| Densité app. GL1            | 589 | 0          | 1063.5  | 591.0      | 0.0    | 2240.0  | entrée |
| Densité app. GL2            | 589 | 0          | 354.3   | 574.6      | 0.0    | 1860.0  | entrée |
| Cendres volantes            | 589 | 0          | 31.20   | 66.39      | 0.00   | 381.70  | entrée |
| Fumée de silice             | 589 | 0          | 4.797   | 15.315     | 0.000  | 92.000  | entrée |
| Autres additifs             | 589 | 0          | 9.82    | 36.11      | 0.00   | 330.00  | entrée |
| Résistance à la compression | 589 | 0          | 27.596  | 17.118     | 0.000  | 72.440  | sortie |

**Tableau 4.4 :** Caractéristiques statistiques des variables d'entrée et de la propriété cible 'Résistance à la traction (RT)'


| Paramètre                | N   | Manquantes | Moyenne | Ecart-type | Min    | Max    | Type   |
|--------------------------|-----|------------|---------|------------|--------|--------|--------|
| Ciment                   | 285 | 0          | 471.8   | 182.7      | 0.0    | 1393.5 | entrée |
| E/L                      | 285 | 0          | 0.4180  | 0.0836     | 0.1090 | 0.6800 | entrée |
| Sable                    | 285 | 0          | 507.3   | 345.1      | 0.0    | 958.0  | entrée |
| Granulats ordinaires     | 285 | 0          | 213.9   | 332.4      | 0.0    | 1593.0 | entrée |
| Granulats légers type 1  | 285 | 0          | 258.9   | 230.3      | 0.0    | 956.9  | entrée |
| Granulats légers type 2  | 285 | 0          | 94.12   | 165.75     | 0.00   | 830.00 | entrée |
| Superplastifiant         | 285 | 0          | 2.623   | 3.307      | 0.000  | 17.500 | entrée |
| Densité app. GL1         | 285 | 0          | 882.6   | 405.5      | 0.0    | 1890.0 | entrée |
| Densité app. GL2         | 285 | 0          | 442.3   | 586.2      | 0.0    | 1860.0 | entrée |
| Cendres volantes         | 285 | 0          | 45.13   | 82.19      | 0.00   | 381.70 | entrée |
| Fumée de silice          | 285 | 0          | 5.376   | 15.601     | 0.000  | 82.000 | entrée |
| Autres additifs          | 285 | 0          | 14.29   | 37.81      | 0.00   | 180.00 | entrée |
| Résistance à la traction | 285 | 0          | 2.5881  | 1.0346     | 0.3700 | 6.1500 | sortie |

#### 4.1.2 Corrélations entre les variables :


Les matrices de corrélation présentées dans les figures 4.1 , 4.2,4.3 et 4.4 illustrent les relations linéaires entre les variables d'entrée et chacune des propriétés cibles. Cette analyse met en évidence des interactions complexes entre les constituants du mélange et les propriétés mécaniques du béton léger. Certaines variables, telles que le dosage en ciment et le rapport E/L, présentent des corrélations significatives avec les propriétés cibles, ce qui est cohérent avec les connaissances physiques sur le comportement du béton. En revanche, d'autres paramètres affichent des corrélations plus faibles ou non linéaires, justifiant ainsi le recours à des modèles d'apprentissage automatique capables de capturer des interactions complexes que les approches statistiques classiques ne peuvent pas modéliser fidèlement.




**Figure 4.1 :** Matrice de corrélation entre les variables d'entrée et la propriété cible 'Masse volumique du béton (MVB)



**Figure 4.2 :** Matrice de corrélation entre les variables d'entrée et la propriété cible — Module d'élasticité (ME)



**Figure 4.3 :** Matrice de corrélation entre les variables d'entrée et la propriété cible 'Résistance à la compression (RC)




**Figure 4.4 :** Matrice de corrélation entre les variables d'entrée et la propriété cible 'Résistance à la traction (RT)


## 4.2 Résultats et interprétation du modèle SVM :

Le principal atout du modèle SVM réside dans sa capacité à modéliser des relations non linéaires complexes et à maintenir une performance acceptable sur des données de nature variée. Toutefois, plusieurs limites ont été


observées. La dispersion des points prédits autour de la droite idéale est plus prononcée que pour les autres modèles, en particulier pour la MVB et la RT. Par ailleurs, les valeurs de RMSE obtenues sont globalement plus élevées, révélant une instabilité de la précision selon le type de propriété modélisée. Ces résultats suggèrent que le modèle SVM, bien qu'acceptable pour une première approximation, présente des limitations dans le cadre d'une prédiction à haute précision des propriétés mécaniques du béton léger.




**Figure 4.5 :** Performances du modèle SVM pour la prédiction de la masse volumique du béton (MVB)



**Figure 4.6 :** Performances du modèle SVM pour la prédiction du module d'élasticité (ME)



**Figure 4.7 :** Performances du modèle SVM pour la prédiction de la résistance à la compression



**Figure 4.8 :** Performances du modèle SVM pour la prédiction de la résistance à la traction

Les figures 4.5 à 4.8 présentent les résultats obtenus avec le modèle SVM sous forme de graphiques comparant les valeurs expérimentales aux valeurs prédites pour les quatre propriétés cibles. Bien que les points soient relativement dispersés autour de la droite de régression idéale, l'algorithme parvient à reproduire la tendance générale des données avec une précision acceptable.


#### 4.2.1 Performance sur l'ensemble de test :

L'analyse des métriques d'évaluation révèle des performances variables selon la propriété considérée. Le modèle SVM affiche sa meilleure performance pour le module d'élasticité (ME), avec un coefficient de détermination  $R^2 = 0,9214$ , indiquant une bonne capacité de généralisation pour cette propriété. En revanche, les performances sont moins satisfaisantes pour la masse volumique du béton (MVB) et la résistance à la traction (RT), avec des coefficients de détermination respectifs de 0,8021 et 0,8183, accompagnés de valeurs de RMSE relativement élevées.


par rapport aux autres modèles étudiés.

### 4.3 Résultats et interprétation du modèle ANN :


La distribution resserrée des points autour de la droite d'identité ( $y = x$ ) sur l'ensemble des graphiques témoigne de la capacité du modèle ANN à reproduire fidèlement des relations non linéaires complexes entre les variables d'entrée et les propriétés cibles. Par ailleurs, la convergence des performances entre les phases d'entraînement et de test souligne l'aptitude du réseau à la généralisation et sa résistance au surapprentissage (overfitting), garantissant ainsi la stabilité et la fiabilité des prédictions produites. Ces résultats positionnent le modèle ANN comme l'un des algorithmes les plus performants parmi ceux étudiés dans le cadre de ce travail.




**Figure 4.9** : Performances du modèle ANN (MVB)



**Figure 4.10** : Performances du modèle ANN (ME)



**Figure 4.11** : Performances du modèle ANN (RC)



**Figure 4.12** : Performances du modèle ANN (RT)

Les figures 4.9 à 4.12 présentent les graphiques de régression illustrant les performances du modèle de Réseaux de Neurones Artificiels (ANN) pour la prédiction des quatre propriétés physiques et mécaniques du béton léger, à savoir la résistance à la compression (RC), la résistance à la traction (RT), le module d'élasticité (ME) et la masse volumique du béton (MVB).


#### 4.3.1 Performance sur l'ensemble de test :

Les résultats statistiques obtenus démontrent une performance élevée du modèle ANN pour l'ensemble des propriétés étudiées. Les coefficients de détermination ( $R^2$ ) se stabilisent à des niveaux compris entre 0,92 et 0,97,


indiquant que le modèle est capable d'expliquer plus de 92 % de la variance des données expérimentales. Les valeurs de RMSE obtenues sont faibles, reflétant un écart réduit entre les valeurs réelles et les valeurs prédites, ce qui confirme la précision et la fiabilité du modèle.

## 4.4 Résultats et interprétation du modèle Random Forest :


Les figures 4.13 à 4.16 présentent les graphiques de régression illustrant les performances du modèle Forêt Aléatoire (Random Forest) pour la prédiction des quatre propriétés physiques et mécaniques du béton léger. La distribution resserrée des points autour de la droite d'identité ( $y = x$ ) témoigne de l'efficacité et de la précision de cet algorithme pour l'ensemble des propriétés étudiées.




**Figure 4.13 :** Performances du modèle Random Forest pour la prédiction de la masse volumique du béton (MVB)



**Figure 4.14 :** Performances du modèle Random Forest pour la prédiction du module d'élasticité (ME)



**Figure 4.15 :** Performances du modèle Random Forest pour la prédiction de la résistance à la compression (RC)



**Figure 4.16 :** Performances du modèle Random Forest pour la prédiction de la résistance à la traction (RT)


### 4.4.1 Performance et analyse des erreurs

Les métriques d'évaluation obtenues confirment la haute performance du modèle Forêt Aléatoire (Random Forest) pour l'ensemble des propriétés étudiées. Les coefficients de détermination ( $R^2$ ) obtenus sur l'ensemble de test atteignent 0,96 pour la masse volumique du béton (MVB), 0,94 pour le module d'élasticité (ME), 0,92


pour la résistance à la compression (RC) et 0,97 pour la résistance à la traction (RT). Ces valeurs indiquent que le modèle est capable d'expliquer plus de 92 % de la variance des données expérimentales pour l'ensemble des propriétés étudiées, avec une performance particulièrement remarquable pour la résistance à la traction. Les valeurs de RMSE obtenues sont faibles et stables entre les phases d'entraînement et de test, reflétant une réduction significative de l'écart entre les prédictions et les observations réelles. La convergence des performances entre ces deux phases confirme la capacité du modèle à généraliser ses prédictions sur des données non vues, sans présenter de phénomène de surapprentissage (overfitting), ce qui constitue l'un des atouts majeurs du modèle Random Forest par rapport aux autres algorithmes étudiés.

## 4.5 Résultats et interprétation du modèle XGBoost :


Les figures 4.17 à 4.20 illustrent les performances du modèle XGBoost pour la prédiction des quatre propriétés mécaniques et physiques du béton léger. Les prédictions suivent avec une très grande précision la droite d'identité ( $y = x$ ), reflétant la puissance de cet algorithme pour modéliser des relations non linéaires complexes avec des erreurs de prédiction très réduites. Les métriques d'évaluation obtenues confirment la très haute performance du modèle XGBoost pour l'ensemble des propriétés étudiées. Les coefficients de détermination ( $R^2$ ) obtenus sur l'ensemble de test atteignent 0,97 pour la masse volumique du béton (MVB), 0,96 pour le module d'élasticité (ME), 0,97 pour la résistance à la compression (RC) et 0,95 pour la résistance à la traction (RT). Ces valeurs indiquent que le modèle est capable d'expliquer plus de 95 % de la variance des données expérimentales pour l'ensemble des propriétés étudiées, positionnant XGBoost comme l'algorithme le plus performant parmi ceux étudiés dans ce travail. Toutefois, un écart notable est observé entre les performances en phase d'entraînement ; où le  $R^2$  atteint 1 ; et celles obtenues en validation et en test. Cet écart, bien que les résultats en test demeurent excellents, indique une légère tendance au surapprentissage (overfitting) qui mérite une attention particulière lors de l'application pratique du modèle. Malgré cette réserve, XGBoost constitue l'algorithme le plus précis parmi les quatre modèles étudiés dans le cadre de cette étude




**Figure 4.17 :** Performances du modèle XGBoost pour la prédiction de la masse volumique du béton (MVB)



**Figure 4.18 :** Performances du modèle XGBoost pour la prédiction du module d'élasticité (ME)



**Figure 4.19 :** Performances du modèle XGBoost pour la prédiction de la résistance à la compression (RC)



**Figure 4.20 :** Performances du modèle XGBoost pour la prédiction de la résistance à la traction (RT)

## 4.6 Comparaison globale des modèles :

Le tableau 4.5 synthétise les performances des quatre modèles d'apprentissage automatique étudiés; ANN, XGBoost, Random Forest et SVM; à travers les trois phases d'évaluation (entraînement, validation et test), en utilisant le coefficient de détermination ( $R^2$ ) et l'erreur quadratique moyenne (RMSE) comme métriques d'évaluation.

**Tableau 4.5 :** Comparaison globale des performances des modèles d'apprentissage automatique

| Propriété                        | Modèle               | $R^2$ Entraînement | $R^2$ Validation | $R^2$ Test  | RMSE Test    |
|----------------------------------|----------------------|--------------------|------------------|-------------|--------------|
| Masse volumique (MVB)            | ANN                  | 0,9838             | 0,9547           | 0,94        | 134,26       |
|                                  | <b>XGBoost</b>       | 1,0000             | 0,9650           | <b>0,97</b> | <b>97,36</b> |
|                                  | Random Forest        | 0,9925             | 0,9597           | 0,96        | 106,55       |
|                                  | SVM                  | 0,8176             | 0,7660           | 0,80        | 179,58       |
| Module d'élasticité (ME)         | ANN                  | 0,9858             | 0,8955           | 0,93        | 3,15         |
|                                  | <b>XGBoost</b>       | 0,9978             | 0,9388           | <b>0,96</b> | <b>3,59</b>  |
|                                  | Random Forest        | 0,9895             | 0,9341           | 0,94        | 3,64         |
|                                  | SVM                  | 0,9608             | 0,6718           | 0,92        | 3,17         |
| Résistance à la compression (RC) | ANN                  | 0,9872             | 0,8871           | 0,92        | 6,76         |
|                                  | <b>XGBoost</b>       | 1,0000             | 0,8883           | <b>0,97</b> | <b>5,16</b>  |
|                                  | Random Forest        | 0,9875             | 0,8809           | 0,92        | 5,16         |
|                                  | SVM                  | 0,8832             | 0,6285           | 0,83        | 6,95         |
| Résistance à la traction (RT)    | ANN                  | 0,9972             | 0,9331           | <b>0,97</b> | 0,30         |
|                                  | XGBoost              | 1,0000             | 0,9154           | 0,95        | 0,27         |
|                                  | <b>Random Forest</b> | 0,9885             | 0,9264           | <b>0,97</b> | <b>0,22</b>  |
|                                  | SVM                  | 0,9612             | 0,5812           | 0,81        | 0,84         |

**Tableau 4.6 :** Récapitulatif des  $R^2$  sur l'ensemble de test

| Propriété                        | SVM         | ANN         | Random Forest | XGBoost     | Meilleur modèle     |
|----------------------------------|-------------|-------------|---------------|-------------|---------------------|
| Masse volumique (MVB)            | 0,80        | 0,94        | 0,96          | <b>0,97</b> | XGBoost             |
| Module d'élasticité (ME)         | 0,92        | 0,93        | 0,94          | <b>0,96</b> | XGBoost             |
| Résistance à la compression (RC) | 0,83        | 0,92        | 0,92          | <b>0,97</b> | XGBoost             |
| Résistance à la traction (RT)    | 0,81        | <b>0,97</b> | <b>0,97</b>   | 0,95        | ANN = Random Forest |
| Moyenne globale                  | <b>0,84</b> | <b>0,94</b> | <b>0,95</b>   | <b>0,96</b> | <b>XGBoost</b>      |

#### 4.6.1 Discussion sur le meilleur modèle pour chaque propriété :

L'analyse comparative des tableaux 4.5 et 4.6 met en évidence des performances distinctes selon les modèles et les propriétés étudiées.

- **Pour la masse volumique du béton (MVB) :** XGBoost affiche les meilleures performances avec un  $R^2$  de 0,97 et un RMSE de 97,36 sur l'ensemble de test, suivi de Random Forest ( $R^2 = 0,96$ , RMSE = 106,55) et d'ANN ( $R^2 = 0,94$ , RMSE = 134,26). Le modèle SVM présente les performances les plus faibles avec un  $R^2$  de 0,80 et un RMSE de 179,58, soit plus du double du RMSE obtenu par XGBoost, indiquant une capacité insuffisante à modéliser cette propriété.
- **Pour le module d'élasticité (ME) :** XGBoost se distingue à nouveau avec le meilleur  $R^2$  de 0,96, suivi de Random Forest ( $R^2 = 0,94$ ), ANN ( $R^2 = 0,93$ ) et SVM ( $R^2 = 0,92$ ). Les quatre modèles présentent des performances relativement proches pour cette propriété, avec des valeurs de RMSE comparables comprises entre 3,15 et 3,64, ce qui suggère que les relations entre les variables d'entrée et le module d'élasticité sont mieux appréhendées par l'ensemble des algorithmes étudiés.
- **Pour la résistance à la compression (RC) :** XGBoost surpasse nettement les autres modèles avec un  $R^2$  de 0,97 et un RMSE de 5,16 sur l'ensemble de test. ANN et Random Forest obtiennent des performances identiques avec un  $R^2$  de 0,92, tandis que le modèle SVM affiche un  $R^2$  de 0,83 et un RMSE de 6,95, confirmant ses limitations pour la modélisation de cette propriété mécanique complexe.
- **Pour la résistance à la traction (RT) :** ANN et Random Forest se distinguent ex æquo avec le meilleur  $R^2$  de 0,97, Random Forest obtenant toutefois le RMSE le plus faible de 0,22, devant ANN (RMSE = 0,30) et XGBoost ( $R^2 = 0,95$ , RMSE = 0,27). Le modèle SVM affiche les performances les plus faibles avec un  $R^2$  de 0,81 et un RMSE de 0,84, soit près de quatre fois supérieur à celui de Random Forest, indiquant une incapacité significative à modéliser le comportement en traction du béton léger.

#### 4.6.2 Analyse des écarts et recommandations pour la pratique :

L'examen des écarts entre les phases d'entraînement et de test, illustré dans le tableau 4.5, révèle des comportements distincts selon les modèles.

- XGBoost présente les écarts les plus importants entre les phases d'entraînement et de test. En effet, le modèle atteint un  $R^2$  de 1 en entraînement pour la MVB et la RC, contre 0,97 en test, et pour la RT, il passe de 1 en entraînement à 0,95 en test. Bien que ces résultats en test demeurent excellents, cette différence traduit une légère tendance au surapprentissage (overfitting) qui doit être prise en compte lors du déploiement pratique du modèle.
- ANN présente des écarts modérés entre les phases, notamment pour la RC où le  $R^2$  passe de 0,98 en entraînement à 0,92 en test, et pour le ME où il passe de 0,98 à 0,93. Ces écarts restent néanmoins acceptables et n'affectent pas significativement la fiabilité globale du modèle.

- Random Forest se distingue par sa stabilité remarquable entre les différentes phases d'évaluation. Les écarts entre les  $R^2$  d'entraînement et de test sont très faibles pour l'ensemble des propriétés ; par exemple, pour la MVB, le  $R^2$  passe de 0,99 en entraînement à 0,96 en test, et pour la RT de 0,98 à 0,97 ; ce qui en fait le modèle le plus robuste et le plus cohérent parmi ceux étudiés.
- SVM présente les performances les plus faibles et les plus instables, avec des écarts importants entre les phases de validation et de test. Pour le ME, le  $R^2$  chute de 0,96 en entraînement à 0,67 en validation avant de remonter à 0,92 en test, révélant une instabilité significative. Pour la RT, il passe de 0,96 en entraînement à 0,58 en validation et 0,81 en test, confirmant les limitations de cet algorithme face à la complexité des données du béton léger. Sur la base de ces observations, les recommandations suivantes peuvent être formulées :
- XGBoost est recommandé lorsque la précision maximale est prioritaire, notamment pour la prédiction de la MVB ( $R^2 = 0,97$ , RMSE = 97,36) et de la RC ( $R^2 = 0,97$ , RMSE = 5,16).
- Random Forest est recommandé comme alternative stable et fiable pour l'ensemble des propriétés, et constitue le meilleur choix pour la RT ( $R^2 = 0,97$ , RMSE = 0,22) grâce à sa stabilité entre les phases.
- ANN constitue un choix pertinent pour la prédiction de la RT, où il égale les performances de Random Forest avec un  $R^2$  de 0,97, et représente une alternative acceptable pour les autres propriétés.
- SVM n'est pas recommandé dans le cadre de cette étude en raison de ses performances globalement inférieures, de son instabilité entre les phases d'évaluation et de ses valeurs de RMSE élevées pour l'ensemble des propriétés étudiées.

## 4.7 Comparaison des performances des modèles développés avec les travaux de la littérature :

Afin d'évaluer la pertinence des modèles développés, leurs performances sont comparées à celles rapportées dans quelques travaux de la littérature scientifique portant sur la prédiction des propriétés des bétons légers par apprentissage automatique. Cette comparaison permet de positionner scientifiquement les modèles développés par rapport à l'état de l'art, à travers trois constats majeurs.

1. **Supériorité des modèles de boosting par gradient** : En accord avec les conclusions de [20,37], qui ont obtenu des coefficients de détermination de  $R^2 = 0,99$  en recourant respectivement à des algorithmes GPR et Ensemble Trees, le modèle XGBoost développé dans ce travail a atteint  $R^2 = 0,97$  pour la résistance à la compression et la masse volumique, et  $R^2 = 0,96$  pour le module d'élasticité. Ces performances surpassent nettement celles des approches basées sur les réseaux de neurones artificiels issues d'études antérieures, notamment [38] avec  $R^2 = 0,91$  et [39] avec  $R^2 = 0,94$  pour la résistance à la compression.
2. **Précision** : couverture multiprédicative et contribution originale. Pour la résistance à la compression, un  $R^2 = 0,97$  a été atteint avec XGBoost, valeur supérieure à celle de [39] avec  $R^2 = 0,94$ , et comparable à celle de [30] avec  $R^2 = 0,97$  pour le coefficient de Poisson. De même, pour le module d'élasticité, un  $R^2 = 0,96$  a été obtenu, dépassant le  $R^2 = 0,93$  rapporté par [36] pour cette même propriété. Par ailleurs, la résistance à la traction a atteint  $R^2 = 0,95$ , une valeur comparable aux  $R^2 = 0,94$  et  $R^2 = 0,98$  obtenus par [37] pour les résistances à la traction par flexion et axiale respectivement.

Il convient de souligner que ce travail constitue, à notre connaissance, la première application de l'algorithme Random Forest à la prédiction simultanée des propriétés mécaniques et physiques des bétons légers dans ce contexte, lequel a permis d'atteindre un coefficient de détermination de  $R^2 = 0,97$  pour la masse volumique, démontrant ainsi son potentiel encore peu exploité dans ce domaine. L'apport distinctif de ce travail réside également dans le fait que ces performances élevées ont été maintenues simultanément pour quatre propriétés cibles, RC, RT, MVB et ME, en mobilisant douze variables d'entrée, alors que la majorité des études de référence se limitent à une seule propriété prédite.

3. **Fiabilité et capacité de généralisation** : Les performances obtenues lors de la phase de test confirment la stabilité et la robustesse des modèles développés sur des données non utilisées lors de l'entraînement. La

proximité des résultats avec ceux de [21], qui ont atteint  $R^2 = 0,98$  avec un GPR optimisé pour la résistance à la compression, démontre que l'intégration d'algorithmes avancés et d'une base de données exhaustive permet de réduire significativement l'écart entre les valeurs expérimentales et prédites, en accord avec les critères de fiabilité établis par [37] pour les applications structurales.

**Tableau 4.7 :** Comparaison des performances des modèles développés avec les travaux de la littérature

| Référence   | Algorithmes étudiés                                                                                                                                           | Propriétés prédites                                                                                                                                                                                 | Meilleur modèle       | $R^2$                                                        |
|-------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------|--------------------------------------------------------------|
| Notre étude | <ul style="list-style-type: none"> <li>• SVM</li> <li>• ANN</li> <li>• XGBoost</li> <li>• Random Forest</li> </ul>                                            | <ul style="list-style-type: none"> <li>• Masse volumique</li> <li>• Module d'élasticité</li> <li>• Résistance à la traction</li> <li>• Résistance à la compression</li> </ul>                       | <b>XGBoost</b>        | $R^2 = 0.97$<br>$R^2 = 0.96$<br>$R^2 = 0.95$<br>$R^2 = 0.97$ |
| [20]        | <ul style="list-style-type: none"> <li>• SVM</li> <li>• ANN</li> <li>• DT</li> <li>• GPR</li> <li>• XGBoost</li> </ul>                                        | <ul style="list-style-type: none"> <li>• Résistance à la compression</li> </ul>                                                                                                                     | <b>GPR</b>            | $R^2 = 0.99$                                                 |
| [37]        | <ul style="list-style-type: none"> <li>• DNN</li> <li>• Ensemble Trees</li> </ul>                                                                             | <ul style="list-style-type: none"> <li>• Résistance à la compression (cubique et prismatique)</li> <li>• Résistance à la traction par flexion</li> <li>• Résistance à la traction axiale</li> </ul> | <b>Ensemble Trees</b> | $R^2 = 0.99$<br>$R^2 = 0.99$<br>$R^2 = 0.94$<br>$R^2 = 0.98$ |
| [21]        | <ul style="list-style-type: none"> <li>• GPR</li> <li>• SVMR</li> <li>• EL</li> <li>• GPR optimisé</li> <li>• SVMR optimisé</li> <li>• EL optimisé</li> </ul> | <ul style="list-style-type: none"> <li>• Résistance à la compression</li> </ul>                                                                                                                     | <b>GPR optimisé</b>   | $R^2 = 0.98$                                                 |
| [36]        | RNA                                                                                                                                                           | <ul style="list-style-type: none"> <li>• Résistance à la compression</li> <li>• Module d'élasticité</li> </ul>                                                                                      | <b>RNA</b>            | $R^2 = 0.93$<br>$R^2 = 0.97$                                 |
| [38]        | RNA                                                                                                                                                           | <ul style="list-style-type: none"> <li>• Résistance à la compression</li> </ul>                                                                                                                     | <b>RNA</b>            | $R^2 = 0.91$                                                 |
| [39]        | RNA                                                                                                                                                           | <ul style="list-style-type: none"> <li>• Résistance à la compression</li> </ul>                                                                                                                     | <b>RNA</b>            | $R^2 = 0.94$                                                 |
| [30]        | RNA                                                                                                                                                           | <ul style="list-style-type: none"> <li>• Coefficient de Poisson</li> </ul>                                                                                                                          | <b>RNA</b>            | $R^2 = 0.97$                                                 |

En définitive, les résultats obtenus positionnent favorablement ce travail parmi les études récentes en génie civil computationnel. Le modèle XGBoost, avec un  $R^2$  atteignant 0,97 pour deux propriétés cibles, le modèle Random Forest avec  $R^2 = 0,97$  pour la masse volumique, et le modèle ANN avec des performances comparables, démontrent que l'utilisation conjointe d'une base de données diversifiée et d'algorithmes d'apprentissage automatique avancés

constitue un outil prédictif fiable et performant pour les bétons légers, réduisant ainsi significativement le recours aux essais expérimentaux coûteux et les délais de conception.

## 4.8 Présentation de l'application web :

À l'issue de l'analyse comparative des modèles d'intelligence artificielle réalisée dans ce mémoire à l'aide du langage Python, les quatre modèles retenus : XGBoost, Random Forest, les Réseaux de Neurones Artificiels (ANN) et les Machines à Vecteurs de Support (SVM), ont été intégrés dans une application web interactive intitulée « Concrete AI ». Cette application constitue ainsi la concrétisation directe des travaux d'analyse menés tout au long de ce mémoire, en mettant à disposition un outil opérationnel qui reproduit fidèlement les mêmes traitements et prédictions effectués lors de l'étude. L'objectif de cette application est de rendre les modèles développés accessibles à tout utilisateur sans nécessiter de compétences en programmation. Elle offre une interface simple permettant d'importer un fichier CSV contenant les compositions de mélanges de béton léger, et retourne instantanément les prédictions des propriétés mécaniques cibles accompagnées des indicateurs de performance  $R^2$  et RMSE pour chacun des cinq modèles. Il convient de préciser que le développement informatique de cette application ne constitue pas l'objet principal de ce mémoire. Les modèles d'IA utilisés sont exactement les mêmes que ceux entraînés et évalués lors de l'analyse Python présentée dans les chapitres précédents ; l'application web en est uniquement l'interface de déploiement et de mise en usage pratique.



Figure 4.21 : Interface d'accueil du site web Concrete AI

### 4.8.1 Principe de fonctionnement de l'application web :

Le fonctionnement de l'application repose sur les modèles d'IA préalablement entraînés sous Python sur la base de données de bétons légers constituée dans ce mémoire. Une fois les modèles entraînés et validés, ils ont été exportés et intégrés dans l'application web, qui se charge d'exécuter les mêmes prédictions de manière automatisée et interactive. L'utilisateur renseigne les paramètres de composition du mélange via un fichier CSV, et l'application retourne les prédictions des propriétés mécaniques cibles pour l'ensemble des quatre modèles simultanément.

#### 1. Paramètres d'entrée :

Les variables d'entrée correspondent aux composants du mélange de béton léger utilisés lors de l'analyse dans ce mémoire, à savoir : ciment ( $\text{kg}/\text{m}^3$ ), rapport eau/liant (E/L), sable ( $\text{kg}/\text{m}^3$ ), granulats ordinaires ( $\text{kg}/\text{m}^3$ ), granulats légers type 1 et type 2 ( $\text{kg}/\text{m}^3$ ) ainsi que leurs densités apparentes respectives, superplastifiant ( $\text{kg}/\text{m}^3$ ), cendres volantes ( $\text{kg}/\text{m}^3$ ), fumée de silice ( $\text{kg}/\text{m}^3$ ) et autre addition minérale ( $\text{kg}/\text{m}^3$ ).

#### 2. Paramètres de sortie :

Les variables de sortie correspondent aux quatre propriétés mécaniques cibles étudiées dans ce mémoire : résistance à la compression à 28 jours (MPa), résistance à la traction à 28 jours (MPa), masse volumique sèche ( $\text{kg}/\text{m}^3$ ) et le module d'élasticité (GPa). Cette cohérence entre les variables utilisées dans l'analyse Python et celles intégrées dans l'application garantit que les prédictions fournies par l'outil web sont parfaitement conformes aux résultats obtenus lors de l'étude.





Figure 4.22 : Interface de téléchargement des données via fichier CSV

#### 4.8.2 Résultats obtenus via l'application Concrete AI :

L'application web Concrete AI ayant été construite sur la base des mêmes modèles d'IA entraînés et évalués dans ce mémoire, les résultats qu'elle génère sont directement comparables à ceux obtenus lors de l'analyse Python. Afin de vérifier cette cohérence, les mêmes bases de données de béton léger utilisés lors de la phase de test ont été soumis à l'application, et les prédictions retournées par les quatre modèles : XGBoost, Random Forest, ANN et SVM, ont été confrontées aux valeurs expérimentales de référence. Les résultats affichés par l'application sont identiques à ceux issus de l'analyse réalisée sous Python, ce qui confirme que le déploiement des modèles dans l'interface web n'a introduit aucune altération dans les prédictions. Les indicateurs  $R^2$  et RMSE présentés par l'application correspondent fidèlement aux valeurs calculées lors de l'évaluation des modèles, notamment pour ANN et XGBoost qui demeurent les plus performants avec des valeurs de  $R^2$  dépassant 0,90 pour la résistance à la compression. Au-delà de la validation des résultats, l'application Concrete AI représente une valeur ajoutée concrète pour la pratique du génie civil. Elle permet à un ingénieur ou un praticien d'obtenir instantanément les quatre propriétés mécaniques d'un béton léger : résistance à la compression, résistance à la traction, masse volumique sèche et module d'élasticité, sans avoir à recourir à des essais en laboratoire ou à maîtriser des outils de programmation. Cette accessibilité constitue l'un des apports pratiques majeurs de ce travail de mémoire.



**Figure 4.23 :** Évaluation comparative des performances des modèles d'intelligence artificielle implémentés dans l'application Concrete AI

## 4.9 Conclusion :

Ce chapitre a démontré que les modèles d'apprentissage automatique ; ANN, Random Forest et XGBoost ; sont particulièrement performants pour la prédiction des propriétés mécaniques et physiques du béton léger. Ces modèles ont atteint des coefficients de détermination ( $R^2$ ) dépassant 0,92 sur l'ensemble de test pour l'ensemble des propriétés étudiées, confirmant leur capacité à modéliser les relations non linéaires complexes entre les constituants du béton et ses propriétés à l'état durci. Le modèle SVM, en revanche, a affiché les performances les plus faibles avec une moyenne de  $R^2$  de 0,84, le rendant moins adapté à ce type de données.

Sur la base de l'analyse comparative, le modèle XGBoost est recommandé comme modèle principal, ayant surpassé les autres algorithmes pour trois propriétés sur quatre : MVB ( $R^2 = 0,97$ ), ME ( $R^2 = 0,96$ ) et RC ( $R^2 = 0,97$ ) ; avec la moyenne globale de  $R^2$  la plus élevée (0,96). Le modèle Random Forest constitue un excellent second choix, se distinguant par sa stabilité remarquable entre les phases d'évaluation et par ses meilleures performances pour la résistance à la traction ( $R^2 = 0,97$ , RMSE = 0,22). La confrontation de ces résultats avec les travaux de la littérature confirme la valeur scientifique de ce travail. Les performances obtenues surpassent celles des études antérieures basées sur les réseaux de neurones artificiels et sont comparables aux travaux les plus récents utilisant des algorithmes de boosting et d'apprentissage par ensemble. Par ailleurs, ce travail se distingue par une double contribution originale : la première application de l'algorithme Random Forest à la prédiction simultanée de quatre propriétés du béton léger, et le maintien d'une précision élevée pour quatre propriétés cibles (RC, RT, MVB et ME) simultanément, là où la majorité des études de référence se limitent à une seule propriété prédite. Ces résultats ouvrent la voie au chapitre suivant, consacré aux conclusions générales et aux perspectives, notamment en ce qui concerne l'application pratique de ces modèles à l'optimisation des formulations du béton léger et à la réduction du nombre d'essais expérimentaux en laboratoire.

# Conclusion générale

Cette étude constitue une contribution scientifique visant à renforcer l'intégration des techniques de l'intelligence artificielle dans le domaine du génie civil, en se concentrant principalement sur la problématique de la prédiction des propriétés du béton léger. Compte tenu des limites des méthodes expérimentales classiques en termes de coût et de durée, les objectifs fixés ont été atteints grâce au développement de modèles prédictifs précis basés sur des algorithmes d'apprentissage automatique, permettant de simuler le comportement mécanique et physique de ce matériau avec une grande efficacité.

La méthodologie adoptée, fondée sur la constitution d'une base de données de référence soumise à un prétraitement rigoureux, a permis d'aboutir à des résultats probants prouvant le succès des modèles proposés pour prédire la résistance à la compression (RC), la résistance à la traction (RT), la masse volumique sèche (MVB) et le module d'élasticité (ME).

L'analyse comparative des performances des quatre algorithmes utilisés : ANN, Random Forest, SVM et XGBoost, a mis en évidence la supériorité notable du modèle XGBoost, qui a enregistré les niveaux de précision les plus élevés pour trois propriétés sur quatre : la masse volumique sèche ( $R^2 = 0,97$ ), le module d'élasticité ( $R^2 = 0,96$ ) et la résistance à la compression ( $R^2 = 0,97$ ). Le modèle Random Forest a quant à lui démontré une grande efficacité et stabilité, se distinguant particulièrement dans la prédiction de la résistance à la traction avec la meilleure précision ( $R^2 = 0,97$ ).

La valeur scientifique de ce travail réside dans la présentation d'une étude globale couvrant simultanément quatre propriétés fondamentales, ce qui constitue une valeur ajoutée qualitative et une application pionnière de l'algorithme Random Forest sur ce type de données. Malgré ces résultats positifs, l'étude reste soumise à certaines limites, notamment la taille et la diversité de la base de données ainsi que l'absence de vérification expérimentale directe pour certains cas extrêmes.

# Perspectives et recommandations

Les résultats de ce travail ouvrent plusieurs axes de recherche prometteurs pour les études futures :

1. **Élargissement de la base de données** : intégrer de nouvelles études portant sur des formulations innovantes incluant des granulats recyclés et des additions minérales non conventionnelles, afin d'améliorer la robustesse et la capacité de généralisation des modèles développés.
2. **Intégration de nouvelles propriétés cibles** : étendre la modélisation à d'autres propriétés de durabilité telles que la perméabilité, le retrait, le fluage et la résistance aux cycles gel-dégel, afin de disposer d'un outil prédictif plus complet pour les applications structurelles en génie civil.
3. **Application à d'autres types de bétons** : appliquer les modèles développés à d'autres familles de bétons, notamment le béton autoplaçant (BAP) et le béton à granulats recyclés, afin d'élargir le champ d'application de cette approche.
4. **Développement d'un outil numérique de prédiction** : concevoir une application web ou un outil numérique interactif intégrant les modèles développés, permettant aux ingénieurs et aux chercheurs d'optimiser les formulations de bétons légers avant la phase de fabrication et de réduire significativement le recours aux essais expérimentaux coûteux.

# Bibliographie

- [1] A. M. Neville, *Propriétés des bétons*. Paris : Editions Eyrolles, 2000.
- [2] L. Breiman, “Random forests,” *Machine learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [3] S. Chandra and L. Berntsson, “Historical background of lightweight aggregate concrete,” *Lightweight Aggregate Concrete*, pp. 5–19, 2002.
- [4] G. Dreux and J. Festa, *Nouveau guide du béton et de ses constituants*. Eyrolles, 1998.
- [5] M. Contant, “Confection de bétons légers pour la fabrication d’éléments architecturaux,” *Projet d’application présenté à l’Ecole de Technologie Supérieure*, 2001.
- [6] “Les additions minérales pour béton,” <https://www.infociments.fr/betons/les-additions-minerales-pour-beton>, 2020. Infociments.
- [7] <https://www.acpresse.fr/les-cendres-volantes/>.
- [8] <https://www.acpresse.fr/fumee-de-silice-approche-environnementale-securitaire-et-sanitaire/>.
- [9] <https://www.buzzi.com/web/gulf-cement-company/ggbs/>.
- [10] <https://transitube.com/fiche-matiere/metakaolin/>.
- [11] T. Lo, H. Cui, and Z. Li, “Influence of aggregate pre-wetting and fly ash on mechanical properties of lightweight concrete,” *Waste management*, vol. 24, no. 4, pp. 333–338, 2004.
- [12] M. Shink, “Compatibilité élastique, comportement mécanique et optimisation des bétons de granulats légers,” 2003.
- [13] D. HADDOURI, “Les bétons légers et très légers,” 2024.
- [14] K. Ait Tahar, “Avant tout. louangea dieu le tout puissant, le miséricordieux...,”
- [15] V. Cérézo, “Propriétés mécaniques, thermiques et acoustiques d’un matériau à base de particules végétales,” *L’Institut National des Sciences Appliquées de Lyon*, 2005.
- [16] M.-H. Zhang and O. E. Gjorv, “Characteristics of lightweight aggregates for high-strength concrete,” *Materials Journal*, vol. 88, no. 2, pp. 150–158, 1991.
- [17] M. Bouchemoukha, D. Boukelia, F. Rechak, and I. E. Hallal, *Centre nautique au port de pêche à Jijel*. PhD thesis, Université de Jijel, 2018.
- [18] A. Carles-Gibergues, M. Pigeon, *et al.*, “La durabilité des bétons en ambiance hivernale rigoureuse,” *La durabilité du béton*, pp. 227–284, 1992.
- [19] A. M. Bastos, H. Sousa, and A. F. Melo, “Methodology for the design of lightweight concrete with expanded clay aggregates,” *The Masonry Society Journal*, vol. 23, no. 1, pp. 73–84, 2005.
- [20] F. Hussain, S. Ali Khan, R. A. Khushnood, A. Hamza, and F. Rehman, “Machine learning-based predictive modeling of sustainable lightweight aggregate concrete,” *Sustainability*, vol. 15, no. 1, p. 641, 2022.
- [21] A. Kumar, H. C. Arora, N. R. Kapoor, M. A. Mohammed, K. Kumar, A. Majumdar, and O. Thinnukool, “Compressive strength prediction of lightweight concrete : Machine learning models,” *Sustainability*, vol. 14, no. 4, p. 2404, 2022.
- [22] C. Touzet, *les réseaux de neurones artificiels, introduction au connexionnisme*. Ec2, 1992.

- [23] M. Lokhande, M. Chougule, S. Lokhande, D. Jadhav, and C. Chaware, "Applications of artificial intelligence and machine learning in civil engineering : a review," *J Civil Environ Engg*, vol. 12, no. 12, pp. 223–232, 2024.
- [24] D. W. Scott, *Multivariate density estimation : theory, practice, and visualization*. John Wiley & Sons, 2015.
- [25] P. Feng, Z. Bi, Y. Wen, X. Pan, B. Peng, M. Liu, J. Xu, K. Chen, J. Liu, C. H. Yin, *et al.*, "Deep learning and machine learning, advancing big data analytics and management : Unveiling ai's potential through tools, techniques, and applications," *arXiv preprint arXiv :2410.01268*, 2024.
- [26] R. C. Luo and M. G. Kay, "Multisensor integration and fusion in intelligent systems," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 19, no. 5, pp. 901–931, 1989.
- [27] <https://www.databricks.com/fr/blog/supervised-vs-unsupervised-learning>.
- [28] <https://serokell.io/blog/polynomial-regression-analysis>.
- [29] <https://www.datacamp.com/fr/tutorial/understanding-logistic-regression-python>.
- [30] M. Davraz, . Kılınçarslan, and H. Ceylan, "Predicting the poisson ratio of lightweight concretes using artificial neural network," *Acta Physica Polonica A*, vol. 128, no. 2B, 2015.
- [31] M. M. Moein, A. Saradar, K. Rahmati, S. H. G. Mousavinejad, J. Bristow, V. Aramali, and M. Karakouzian, "Predictive models for concrete properties using machine learning and deep learning approaches : A review," *Journal of Building Engineering*, vol. 63, p. 105444, 2023.
- [32] N. A. Ibrahim and K. Kusnawi, "Ex-boost : An integrated exploratory data analysis and extreme gradient boosting framework for forecasting future job opportunities," in *2025 2nd Beyond Technology Summit on Informatics International Conference (BTS-I2C)*, pp. 640–645, IEEE, 2025.
- [33] A. Gulli and S. Pal, *Deep learning with Keras*. Packt Publishing Ltd, 2017.
- [34] <https://www.istockphoto.com/photos/deep-learning>.
- [35] <https://www.geeksforgeeks.org/deep-learning/tanh-vs-sigmoid-vs-relu/>.
- [36] J. Y. Yoon, H. Kim, Y.-J. Lee, and S.-H. Sim, "Prediction model for mechanical properties of lightweight aggregate concrete using artificial neural network," *Materials*, vol. 12, no. 17, p. 2678, 2019.
- [37] S. A. Stel'makh, E. M. Shcherban', A. N. Beskopylny, L. R. Mailyan, B. Meskhi, I. Razveeva, A. Kozhakin, and N. Beskopylny, "Prediction of mechanical properties of highly functional lightweight fiber-reinforced concrete based on deep neural network and ensemble regression trees methods," *Materials*, vol. 15, no. 19, p. 6740, 2022.
- [38] T. K. Šipoš, I. Miličević, and R. Siddique, "Model for mix design of brick aggregate concrete based on neural network modelling," *Construction and building materials*, vol. 148, pp. 757–769, 2017.
- [39] A. J. Tenza-Abril, Y. Villacampa, A. M. Solak, and F. Baeza-Brotons, "Prediction and sensitivity analysis of compressive strength in segregated lightweight concrete based on artificial neural network using ultrasonic pulse velocity," *Construction and building materials*, vol. 189, pp. 1173–1183, 2018.
- [40] W. Yao, J. Pang, and Y. Liu, "Performance degradation and microscopic analysis of lightweight aggregate concrete after exposure to high temperature," *Materials*, vol. 13, p. 1566, 2020.
- [41] L. Domagała, "Size effect in compressive strength tests of cored specimens of lightweight aggregate concrete," *Materials*, vol. 13, p. 1187, 2020.
- [42] T. Parhizkar, M. Najimi, and A. R. Pourkhorshidi, "Application of pumice aggregate in structural lightweight concrete," *Asian Journal of Civil Engineering*, vol. 13, pp. 43–54, 2012.
- [43] A. Pavithra and D. J. De Rose, "Application of light expanded clay aggregate as replacement of coarse aggregate in concrete pavement," *International Journal of Engineering and Technology*, vol. 7, pp. 1–4, 2018.
- [44] G. Kim, G. Choe, M. Yoon, and T. Lee, "Mechanical properties of light weight concrete at elevated temperature," *International Journal of Precision Engineering and Manufacturing*, vol. 16, pp. 1867–1874, 2015.

- [45] M. Y. Vahabi, B. Tahmouresi, H. Mosavi, and S. F. Aval, "Effect of pre-coating lightweight aggregates on the self-compacting concrete," *Structural Concrete*, vol. 23, pp. 2120–2131, 2021.
- [46] M. Al-lami and E. Al-Saadi, "The relationships between compressive strength and density of polystyrene lightweight concrete and their component ratios," *Journal of Applied Engineering Science*, vol. 19, pp. 175–185, 2021.
- [47] M. N. A. A. Zawawi, K. Muthusamy, A. P. A. Majeed, R. M. Musa, and A. M. A. Budiea, "Mechanical properties of oil palm waste lightweight aggregate concrete with fly ash as fine aggregate replacement," *Journal of Building Engineering*, vol. 27, p. 100924, 2020.
- [48] H. Cui, T. Y. Lo, S. Memon, and W. Xu, "Effect of lightweight aggregates on the mechanical properties and brittleness of lightweight aggregate concrete," *Construction and Building Materials*, vol. 35, pp. 149–158, 2012.
- [49] S. M. S. Hashemi, "Experimental study on mechanical properties of different lightweight aggregate concretes," *Engineering Solid Mechanics*, vol. 2, pp. 201–208, 2014.
- [50] R. Vijayalakshmi and S. Ramanagopal, "Structural concrete using expanded clay aggregate : A review," *Indian Journal of Science and Technology*, vol. 11, pp. 1–12, 2018.
- [51] J. A. Rossignolo, M. V. C. Agnesini, and J. A. Morais, "Properties of high-performance lwac for precast structures with brazilian lightweight aggregates," *Cement and Concrete Composites*, vol. 25, pp. 77–82, 2003.
- [52] L. H. Nguyen, A. L. Beaucour, S. Ortola, and A. Noumowé, "Influence of the volume fraction and the nature of fine lightweight aggregates on the thermal and mechanical properties of structural concrete," *Construction and Building Materials*, vol. 51, pp. 121–132, 2014.
- [53] Y. J. Kim, Y. W. Choi, and M. Lachemi, "Characteristics of self-consolidating concrete using two types of lightweight coarse aggregates," *Construction and Building Materials*, vol. 24, pp. 11–16, 2010.
- [54] N. U. Kockal and T. Ozturan, "Strength and elastic properties of structural lightweight concretes," *Materials & Design*, vol. 32, pp. 2396–2403, 2011.
- [55] U. J. Alengaram, H. Mahmud, and M. Z. Jumaat, "Enhancement and prediction of modulus of elasticity of palm kernel shell concrete," *Materials & Design*, vol. 32, pp. 2143–2148, 2011.
- [56] R. Ahmmad, U. J. Alengaram, M. Z. Jumaat, N. R. Sulong, M. O. Yusuf, and M. A. Rehman, "Feasibility study on the use of high volume palm oil clinker waste in environmental friendly lightweight concrete," *Construction and Building Materials*, vol. 135, pp. 94–103, 2017.
- [57] E. Guneyisi, M. Gesoglu, and E. Booya, "Fresh properties of self-compacting cold bonded fly ash lightweight aggregate concrete with different mineral admixtures," *Materials and Structures*, vol. 45, pp. 1849–1859, 2012.
- [58] J. A. Bogas and A. Gomes, "A simple mix design method for structural lightweight aggregate concrete," *Materials and Structures*, vol. 46, pp. 1919–1932, 2013.
- [59] J. A. Bogas, J. de Brito, and J. M. Figueiredo, "Mechanical characterization of concrete produced with recycled lightweight expanded clay aggregate concrete," *Journal of Cleaner Production*, vol. 89, pp. 187–195, 2015.
- [60] J. M. Chi *et al.*, "Effect of aggregate properties on the strength and stiffness of lightweight concrete," *Cement and Concrete Composites*, vol. 25, pp. 197–205, 2003.
- [61] Y. W. Choi, Y. J. Kim, H. C. Shin, and H. Y. Moon, "An experimental research on the fluidity and mechanical properties of high-strength lightweight self-compacting concrete," *Cement and Concrete Research*, vol. 36, pp. 1595–1602, 2006.
- [62] C. C. Yang and R. Huang, "Approximate strength of lightweight aggregate using micromechanics method," *Advanced Cement Based Materials*, vol. 7, pp. 133–138, 1998.
- [63] O. Kayali, "Fly ash lightweight aggregates in high performance concrete," *Construction and Building Materials*, vol. 22, pp. 2393–2399, 2008.

- [64] M. Gesoglu, T. Özturan, and E. Güneyisi, "Effects of fly ash properties on characteristics of cold-bonded fly ash lightweight aggregates," *Construction and Building Materials*, vol. 21, pp. 1869–1878, 2007.
- [65] M. Aslam, P. Shafigh, M. Z. Jumaat, and M. Lachemi, "Benefits of using blended waste coarse lightweight aggregates in structural lightweight aggregate concrete," *Journal of Cleaner Production*, vol. 119, pp. 108–117, 2016.
- [66] L. Domagała and E. Bryła, "The properties of lightweight aggregates pre-coated with cement pastes and their suitability for concrete," *Materials*, vol. 14, p. 6417, 2021.
- [67] X. Liu, H. Du, and M.-H. Zhang, "A model to estimate the durability performance of both normal and lightweight concrete," *Construction and Building Materials*, vol. 80, pp. 255–261, 2015.
- [68] E. Del Rey Castillo, N. Almesfer, O. Saggi, and J. M. Ingham, "Lightweight concrete with artificial aggregate manufactured from plastic waste," *Construction and Building Materials*, vol. 265, p. 120199, 2020.
- [69] O. M. Ofuyatan, F. Olutoge, D. Omole, and A. Babafemi, "Influence of palm ash on properties of light weight self-compacting concrete," *Cleaner Engineering and Technology*, vol. 4, p. 100233, 2021.
- [70] A. Wongkvanklom *et al.*, "Structural lightweight concrete containing recycled lightweight concrete aggregate," *KSCE Journal of Civil Engineering*, vol. 22, pp. 3077–3084, 2018.
- [71] F. K. Alqahtani, "Sustainable green lightweight concrete containing plastic-based green lightweight aggregate," *Materials*, vol. 14, p. 3304, 2021.
- [72] A. Alabdulkarim *et al.*, "Behavior of lightweight self-compacting concrete with recycled tire steel fibers," *Buildings*, vol. 14, p. 2463, 2024.
- [73] B. A. Graybeal and G. Greene, "Lightweight concrete : Mechanical properties : Techbrief," tech. rep., Federal Highway Administration, 2013.
- [74] O. Uysal *et al.*, "Physical and mechanical properties of lightweight expanded clay aggregate concrete," *Buildings*, vol. 14, p. 1871, 2024.
- [75] S. Hedjazi, "Compressive strength of lightweight concrete," in *Compressive Strength of Concrete*, ch. 11, 2020.
- [76] S. Islam *et al.*, "Development of lightweight structural concrete with artificial aggregate manufactured from local clay and solid waste materials," *Heliyon*, vol. 10, no. 15, 2024.
- [77] R. Szydłowski and B. Łabuzek, "Experimental evaluation of shrinkage, creep and prestress losses in lightweight aggregate concrete with sintered fly ash," *Materials*, vol. 14, p. 3895, 2021.
- [78] H. Zhang, L. Huang, L. Yu, and Z. Yang, "Macromechanical properties and itz of lightweight aggregate concrete from the deck of nanjing yangtze river bridge after 50 years," *Journal of Materials in Civil Engineering*, vol. 32, p. 05020005, 2020.
- [79] A. Radlińska, M. Kaszyńska, A. Zielński, and H. Ye, "Early-age cracking of self-consolidating concrete with lightweight and normal aggregates," *Journal of Materials in Civil Engineering*, vol. 30, p. 04018242, 2018.
- [80] S. M. F. Green, N. J. Brooke, L. G. McSaveney, and J. M. Ingham, "Mixture design development and performance verification of structural lightweight pumice aggregate concrete," *Journal of Materials in Civil Engineering*, vol. 23, pp. 1211–1219, 2011.
- [81] K.-H. Yang, J.-H. Mun, J.-I. Sim, and J.-K. Song, "Effect of water content on the properties of lightweight alkali-activated slag concrete," *Journal of Materials in Civil Engineering*, vol. 23, pp. 886–894, 2011.
- [82] K. Hossain, S. Ahmed, and M. Lachemi, "Lightweight concrete incorporating pumice based blended cement and aggregate : Mechanical and durability characteristics," *Construction and Building Materials*, vol. 25, pp. 1186–1195, 2011.
- [83] O. Fatahi and S. Jafari, "Prediction of lightweight aggregate concrete compressive strength," *Journal of Rehabilitation in Civil Engineering*, vol. 6, pp. 154–163, 2018.
- [84] A. Bicer, "The effect of fly ash and pine tree resin on thermo-mechanical properties of concretes with expanded clay aggregates," *Case Studies in Construction Materials*, vol. 15, p. e00624, 2021.

- [85] A. M. Hameed and B. A. F. Ahmed, "Employment the plastic waste to produce the light weight concrete," *Energy Procedia*, vol. 157, pp. 30–38, 2019.
- [86] P. Shafigh, M. Z. Jumaat, and H. Mahmud, "Mix design and mechanical properties of oil palm shell lightweight aggregate concrete : A review," *International Journal of Physical Sciences*, vol. 5, pp. 2127–2134, 2010.
- [87] H. K. A. Al-Farttoosi, O. A. Abdulrazzaq, and H. K. Hussain, "Mechanical properties of lightweight aggregate concrete using pumice as a coarse aggregate," *IOP Conference Series : Materials Science and Engineering*, vol. 1090, p. 012106, 2021.
- [88] S.-S. Park, Y.-L. Hou, J.-C. Lee, and S.-W. Jeong, "Mechanical properties of concrete with bamboo chips," *Applied Sciences*, vol. 9, p. 3367, 2019.
- [89] L. Domagała, "Durability of structural lightweight concrete with sintered fly ash aggregate," *Materials*, vol. 13, p. 4565, 2020.
- [90] J. Lv, T. Zhou, H. Wu, L. Sang, Z. He, G. Li, and K. Li, "A new composite slab using crushed waste tires as fine aggregate in self-compacting lightweight aggregate concrete," *Materials*, vol. 13, p. 2551, 2020.
- [91] S. A. Almawla, M. K. Mohammed, and A. I. Al-Hadithi, "Fresh and mechanical properties of self-compacting lightweight concrete containing ponza aggregates," in *International Conference on Developments in eSystems Engineering*, (Kazan, Russia), pp. 100–104, 2019.
- [92] J. T. F. Sousa *et al.*, "Self-compacting concrete with artificial lightweight aggregates from sugarcane ash and calcined scheelite mining waste," *Applied Sciences*, vol. 15, p. 452, 2025.
- [93] D. P. P. Meddage, A. Chadee, M. T. R. Jayasinghe, and U. Rathnayake, "Exploring the applicability of expanded polystyrene (eps) based concrete panels as roof slab insulation in the tropics," *Case Studies in Construction Materials*, vol. 17, p. e01361, 2022.
- [94] Y. A. Dolatabad, B. Abolpour, and M. A. J. Tazangi, "Investigating effects of nano particles of silica on the properties of self-compacting concrete containing perlite, leca, and scoria light weight aggregates," *Arabian Journal of Geosciences*, vol. 14, pp. 1–13, 2021.
- [95] M. S. Moayeri, H. R. Ashrafi, and P. Beiranvand, "Investigating the physical characteristics of non-structural lightweight aggregate blocks of built with region materials," *Buildings*, vol. 7, p. 2, 2016.
- [96] Q. Du, Q. Sun, J. Lv, and J. Yang, "Use of preplaced casting method in lightweight aggregate concrete," *Advances in Materials Science and Engineering*, vol. 2017, p. 7234761, 2017.
- [97] H.-J. Chen, C.-H. Huang, and C.-W. Tang, "Dynamic properties of lightweight concrete beams made by sedimentary lightweight aggregate," *Journal of Materials in Civil Engineering*, vol. 22, pp. 599–606, 2010.
- [98] N. N. Hilal, "Hardened properties of self-compacting concrete with different crumb rubber size and content," *International Journal of Sustainable Built Environment*, vol. 6, pp. 191–206, 2017.
- [99] K. S. Elango *et al.*, "Experimental study on self compacting concrete using light weight aggregate," *Materials Today : Proceedings*, vol. 60, pp. 1362–1366, 2022.
- [100] L. Zhu, F. Dang, Y. Xue, W. Ding, and K. Jiao, "Experimental investigation of the thermal and mechanical properties of lightweight aggregate concrete mixed with microencapsulated phase change materials," *International Journal of Energy Research*, vol. 45, pp. 12864–12878, 2021.
- [101] R. Kumar, R. Lakhani, and A. Kumar, "Physico-mechanical and thermal properties of lightweight structural concrete with light expanded clay aggregate for energy-efficient buildings," in *Advances in Construction Materials and Sustainable Environment*, pp. 175–185, Springer Singapore, 2021.
- [102] M. Davraz, Ş. Kiliçarslan, and H. Ceylan, "Predicting the poisson ratio of lightweight concretes using artificial neural network," *Acta Physica Polonica A*, vol. 128, no. 2B, 2015.
- [103] A. J. Tenza-Abril *et al.*, "Prediction and sensitivity analysis of compressive strength in segregated lightweight concrete based on artificial neural network using ultrasonic pulse velocity," *Construction and Building Materials*, vol. 189, pp. 1173–1183, 2018.

- [104] A. H. Gandomi, A. Faramarzifar, P. G. Rezaee, A. Asghari, and S. Talatahari, "New design equations for elastic modulus of concrete using multi expression programming," *Journal of Civil Engineering and Management*, vol. 21, no. 6, pp. 761–774, 2015.
- [105] W. Dong, Y. Huang, B. Lehane, and G. Ma, "Xgboost algorithm-based prediction of concrete electrical resistivity for structural health monitoring," *Automation in Construction*, vol. 114, p. 103155, 2020.

# Annexe A

## Code Listings

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LinearRegression
from sklearn.metrics import mean_squared_error, r2_score
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
from tensorflow.keras.optimizers import Adam

\# --- 1. Chargement des données ---
nom_fichier = '/content/sample_data/BL-DATA-masse_volumique-clean.csv'
df = pd.read_csv(nom_fichier)
X = df.iloc[:, :-1].values
y = df.iloc[:, -1].values
input_dim = X.shape[1]

\# Division des données (70% Entraînement, 15% Validation, 15% Test)
X_train, X_temp, y_train, y_temp = train_test_split(X, y, test_size=0.30, ran
X_val, X_test, y_val, y_test = train_test_split(X_temp, y_temp, test_size=0.50, random_s
\# --- 2. Construction du Réseau de Neurones Artificiels (RNA) ---
modele = Sequential([
    &#x20; Dense(64, activation='relu', input_shape=(input_dim,)),
    &#x20; Dense(128, activation='relu'),
    &#x20; Dense(64, activation='relu'),
    &#x20; Dense(1, activation='linear')
])
```

**Code Listing A.1 :** Code listing du RNA - Masse volumique (importation des bibliothèques, division de la base de données et architecture du réseau de neurones)

```

# CODE DE RNA :
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split
from sklearn.metrics import mean_squared_error, r2_score
from sklearn.preprocessing import StandardScaler
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.callbacks import EarlyStopping

\# --- 1. Chargement des données ---
nom_fichier = '/content/BL-DATA-ME-clean.csv'
df = pd.read_csv(nom_fichier)
X = df.iloc[:, :-1].values
y = df.iloc[:, -1].values

\# Division des données (70% Entraînement, 15% Validation, 15% Test)
X_train, X_temp, y_train, y_temp = train_test_split(X, y, test_size=0.30,
                                                    random_state=42)
X_val, X_test, y_val, y_test = train_test_split(X_temp, y_temp, test_size=0.50,
                                                random_state=42)

\# --- 2. Normalisation des données ---
scaler_X = StandardScaler()
X_train_scaled = scaler_X.fit_transform(X_train)
X_val_scaled = scaler_X.transform(X_val)
X_test_scaled = scaler_X.transform(X_test)
X_all_scaled = scaler_X.transform(X)

\# --- 3. Construction du Réseau de Neurones (RNA) ---
modele = Sequential([
    &x20; Dense(128, activation='relu', input_shape=(X_train_scaled.shape[1],)),
    &x20; Dense(256, activation='relu'),
    &x20; Dropout(0.1),
    &x20; Dense(128, activation='relu'),
    &x20; Dense(64, activation='relu'),
    &x20; Dense(1, activation='linear')
])

```

**Code Listing A.2 :** Code listing du RNA - RC et ME (importation des bibliothèques, division de la base de données, normalisation des données et architecture du réseau de neurones)

```

import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.metrics import r2_score, mean_squared_error
\# =====
\# 1. PRÉPARATION DES DONNÉES
\# df = pd.read_csv('/content/BL-DATA-RT.csv')
np.random.seed(42)
X = np.random.rand(500, 8)
y = (X[:,0]*3 + np.sqrt(X[:,1]) + np.log(X[:,2]+1) + 0.2*np.random.normal(0,1,500))
\# Division des données : Entraînement (70%), Validation (15%), Test (15%)
X_train, X_temp, y_train, y_temp = train_test_split(X, y, test_size=0.3,
random_state=42)
X_val, X_test, y_val, y_test = train_test_split(X_temp, y_temp, test_size=0.5,
random_state=42)
\# Normalisation
scaler_X = StandardScaler()
X_train_sc = scaler_X.fit_transform(X_train)
X_val_sc = scaler_X.transform(X_val)
X_test_sc = scaler_X.transform(X_test)
X_global_sc = scaler_X.transform(X)
\# =====
\# 2. ARCHITECTURE DU RÉSEAU DE NEURONES (RNA)
\# =====
model = Sequential([
    &#x20; Dense(128, activation='relu', input_shape=(X_train.shape[1],)),
    &#x20; Dense(64, activation='relu'),
    &#x20; Dense(32, activation='relu'),
    &#x20; Dense(1)
])

```

**Code Listing A.3 :** Code listing du RNA - RT (importation des bibliothèques, division de la base de données, normalisation des données et architecture du réseau de neurones)

```

modele.compile(optimizer=Adam(learning_rate=0.001), loss='mse')

```

**Code Listing A.4 :** RNA - Compilation du modèle

```

# CODE DE SVR :
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split
from sklearn.preprocessing import StandardScaler
from sklearn.svm import SVR
from sklearn.metrics import r2_score, mean_squared_error

\# =====
\# 1. PRÉPARATION DES DONNÉES
\# =====
\# Chargement de votre fichier réel
path = '/content/BL-DATA-RT.csv'
df = pd.read_csv(path)
\# Séparation automatique (X: entrées, y: cible RT)
X = df.iloc[:, :-1].values
y = df.iloc[:, -1].values
\# Division du jeu de données (70% Entraînement, 15% Validation, 15% Test)
X_train, X_temp, y_train, y_temp = train_test_split(X, y, test_size=0.3,
                                                    random_state=42)
X_val, X_test, y_val, y_test = train_test_split(X_temp, y_temp, test_size=0.5,
                                                random_state=42)
\# Normalisation (Indispensable pour le SVM)
scaler_X = StandardScaler()
X_train_sc = scaler_X.fit_transform(X_train)
X_val_sc = scaler_X.transform(X_val)
X_test_sc = scaler_X.transform(X_test)
X_global_sc = scaler_X.transform(X)
\# =====
\# 2. CONFIGURATION ET ENTRAÎNEMENT DU SVM (SVR)
\# =====
model = SVR(
    &#x20; kernel='rbf',
    &#x20; C=100,          # Régularisation
    &#x20; epsilon=0.01,  # Seuil d'erreur
    &#x20; gamma='scale'
)

```

**Code Listing A.5 :** SVM (importation des bibliothèques, division de la base de données et architecture du modèle SVM)

```

# CODE DE RANDOM FOREST :
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split
from sklearn.metrics import mean_squared_error, r2_score
from sklearn.ensemble import RandomForestRegressor

\# --- 1. Chargement des données ---
nom_fichier = '/content/BL-DATA\'
df = pd.read_csv(nom_fichier)
X = df.iloc[:, :-1].values
y = df.iloc[:, -1].values
\# Division des données (70% Entraînement, 15% Validation, 15% Test)
X_entrainement, X_temp, y_entrainement, y_temp = train_test_split(X, y, test_size=0.30, random_state=42)
X_val, X_test, y_val, y_test = train_test_split(X_temp, y_temp, test_size=0.50, random_state=42)
\# --- 2. Construction et Configuration du Modèle Random Forest ---
\# Configuration robuste pour capturer les relations non-linéaires
modele_rf = RandomForestRegressor(
    &#x20; n_estimators=500,
    &#x20; max_depth=15,
    &#x20; min_samples_split=2,
    &#x20; min_samples_leaf=1,
    &#x20; random_state=42,
    &#x20; n_jobs=-1
)

```

**Code Listing A.6 :** Random Forest (importation des bibliothèques, division de la base de données et

## architecture du modèle Random Forest)

```
# CODE DE xgboost :
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split
from sklearn.metrics import mean_squared_error, r2_score
import xgboost as xgb

\# --- 1. Chargement des données ---
nom_fichier = '/content/BL-DATA\'
df = pd.read_csv(nom_fichier)
X = df.iloc[:, :-1].values
y = df.iloc[:, -1].values

\# Division des données (70% Entraînement, 15% Validation, 15% Test)
X_train, X_temp, y_train, y_temp = train_test_split(X, y, test_size=0.30, random_state=42)
X_val, X_test, y_val, y_test = train_test_split(X_temp, y_temp, test_size=0.50, random_state=42)

\# --- 2. Construction et Configuration du Modèle XGBoost ---
(
    &#x20; n_estimators=1000,
    &#x20; learning_rate=0.05,
    &#x20; max_depth=6,
    &#x20; subsample=0.8,
    &#x20; colsample_bytree=0.8,
    &#x20; objective='reg:squarederror',
    &#x20; random_state=42
)
```

**Code Listing A.7 :** XGBoost (importation des bibliothèques, division de la base de données et architecture du modèle XGBoost)