

UNIVERSITÉ DU QUÉBEC EN ABITIBI-TÉMISCAMINGUE

ÉCOLE NATIONALE DES INGÉNIEURS DE SFAX

**PRÉDICTION DES PROPRIÉTÉS MÉCANIQUES DES REMBLAIS
MINIERS EN PÂTE CIMENTÉS PAR DES APPROCHES DE
L'INTELLIGENCE ARTIFICIELLE (IA)**

MARIEM AMRI

École de génie

Institut de recherche en mines et en environnement (IRME)

MÉMOIRE

PRÉSENTÉ

COMME EXIGENCE PARTIELLE
DE LA MAÎTRISE EN INGÉNIERIE

Avril 2024

DÉDICACE

À ma famille qui m'a offert une éducation empreinte de dignité, j'en suis profondément reconnaissant. Grâce à leur amour et à leur soutien indéfectible, je suis devenu la personne que je suis aujourd'hui.

Je tiens particulièrement à exprimer ma gratitude envers ma mère, Gadra, qui est la source de ma force et de mon énergie. Son amour indéfectible tout au long de ma vie a été une inspiration constante.

À mon cher père, Ahmed, qui a constamment été à mes côtés, me prodiguant son soutien, ses encouragements, et plaçant en moi une confiance inébranlable.

À mes chères sœurs Sabra et Sahar, les mots me manquent pour exprimer pleinement l'amour que je ressens à leur égard. Vous n'avez jamais cessé de me soutenir dans la poursuite de mes objectifs, et pour cela, je suis infiniment reconnaissant.

À mes chers grands-parents.

À mes amis.

REMERCIEMENT

Je remercie avant tout, Dieu, qui m'a donné la santé et la capacité de réussir tout mon cheminement académique durant vingt ans d'éducation et de poursuivre ma maîtrise au Canada qui était mon rêve depuis l'enfance.

Je tiens à exprimer mes plus sincères remerciements à mon directeur de recherche, Monsieur Tikou Belem (Institut de recherche en mines et en environnement – IRME), pour m'avoir offerte l'opportunité de poursuivre ma maîtrise à l'Université du Québec en Abitibi-Témiscamingue, au sein de l'IRME. Je souhaite exprimer ma reconnaissance pour sa contribution scientifique, ses encouragements constants et sa disponibilité inébranlable tout au long de ma formation. Je suis profondément reconnaissante pour son soutien académique, financier et surtout moral. Les enseignements qu'il m'a prodigués vont au-delà du cadre académique, et c'est avec un profond respect que je lui exprime ma gratitude. C'est grâce à mon directeur, en particulier ses citations positives, que j'ai réussi à mener à bien cette maîtrise.

Je tiens également à exprimer ma gratitude envers mon co-directeur, Monsieur Hatem Mrad, pour son engagement continu, débuté dès mon cycle d'ingénierie jusqu'à la conclusion de ma maîtrise. Sa contribution s'étend également à la mise en place de la bidiplomation entre l'École Nationale d'Ingénieurs de Sfax (ENIS) et l'UQAT.

Je souhaite exprimer mes sincères remerciements à Monsieur Louis-Philippe Gélinas pour son soutien et sa disponibilité tout au long de ce projet de recherche. Je lui suis également reconnaissante de m'avoir offert l'opportunité de réaliser un stage MITACS chez Mines Agnico-Eagle Ltée.

À cette occasion, je tiens à exprimer ma profonde gratitude envers Mme Sylvette Awoh et les techniciens de l'URSTM tels que Pierre-Alain Jacques, Guillaume Noirant, Lilas Côté, Joël Beauregard, Alain Perreault, ainsi qu'envers les professeurs et l'équipe administrative (par exemple Charlyse Goupil, Karine Groulx, Luce Turgeon) de l'IRME-UQAT.

Enfin, je souhaite également exprimer ma gratitude à mes proches au Canada : Khouloud, Zeineb, Sofien et Youssef, pour leur soutien moral constant tout au long de ces deux années.

RÉSUMÉ

À l'ère du numérique, l'industrie minière aura besoin de disposer d'outils puissants pour prédire les propriétés mécaniques des remblais miniers pour aider à sélectionner des recettes optimales des mélanges de remblai en pâte cimenté (RPC) dans le but de satisfaire aux contraintes technico-économiques de l'exploitation. Grâce aux progrès récents dans le déploiement de l'intelligence artificielle (IA), l'apprentissage automatique (Machine Learning – ML) et l'apprentissage profond (Deep Learning - DL) sont devenus des techniques de pointe pouvant être employées dans le secteur minier.

C'est dans cette perspective que s'inscrit l'objectif de développer des modèles de Machine Learning et d'un réseau de neurones profond (Deep Neural Network - DNN) pour prédire la résistance à la compression uniaxiale (UCS) des remblais en pâte cimentés. Pour ce faire, de nombreuses données ont été collectées auprès des mines d'Agnico-Eagle pour ajouter à des résultats de laboratoire afin de construire une base de données (BD) riche. Avant l'apprentissage des modèles de ML et le DNN, un prétraitement et des analyses ont été faits sur cette BD en optimisant également les hyperparamètres des modèles. En s'appuyant sur des indicateurs de performance, les modèles de prédiction les plus performants ont été sélectionnés; GBR et DNN qui ont donné des coefficients de détermination (R) égale à 0.970 et 0.969 respectivement. Ces modèles ont été validés au laboratoire par la préparation des nouveaux mélanges de RPC.

Dans le but de mettre ces modèles en production et pour qu'ils soient utilisables par l'industrie minière, une application web sera développée afin de faciliter leurs exécutions par les utilisateurs.

Mots clés : Intelligence artificielle (IA), Base de données, Modèle de prédiction, Résistance à la compression uniaxiale (UCS), Remblai en pâte cimenté (RPC), Application Web.

ABSTRACT

In the digital era, the mining industry benefits from powerful tools that can help to select optimal cement paste backfill (CPB) mix recipes to meet the techno-economic constraints of mining. With recent advances in the deployment of Artificial Intelligence (AI), Machine Learning (ML) and Deep Learning (DL) creates state-of-the-art techniques in the mining sector that can be employed in the mining sector.

This is the perspective behind the objective of developing Machine Learning and Deep Neural Network (DNN) models to predict the uniaxial compressive strength (UCS) of cemented paste backfill. To achieve this, extensive data were collected from Agnico-Eagle's mines and combined with laboratory results to build a rich database (DB). Before training the ML models and DNN, pre-processing and analyses were carried out on this DB, also optimizing the models' hyperparameters.

Based on the performance indicators, the best performing prediction models were selected; GBR and DNN which gave determination coefficients equal to 0.970 and 0.969 respectively. These models were validated in the laboratory by the preparation of new CPB mixtures.

In order to put this model into production and make it usable by the mining industry, a web application will be developed to facilitate its execution by users.

Keywords: Artificial Intelligence (AI), Database, Prediction Model, Uniaxial Compressive Strength (UCS), Cemented Paste Backfill (CPB), Web Application.

TABLE DES MATIÈRES

DÉDICACE	i
REMERCIEMENT	ii
RÉSUMÉ	iii
ABSTRACT.....	iv
TABLE DES MATIÈRES	v
LISTE DES TABLEAUX.....	ix
LISTE DES FIGURES	x
LISTES DES SIGLES ET ABRÉVIATIONS	xiv
LISTE DES ANNEXES	xv
CHAPITRE 1 INTRODUCTION.....	1
1.1. Contexte de l'étude	1
1.2. Problématique de l'étude	2
1.3. Objectifs de l'étude	3
1.4. Hypothèses de recherche.....	4
1.5. Démarche méthodologique de l'étude	4
1.6. Structure du mémoire.....	6
CHAPITRE 2 REVUE DE LITTÉRATURE	7
2.1. Introduction.....	7
2.2. Aperçu sur les remblais miniers.....	7
2.2.1. Remblai hydraulique	8
2.2.2. Remblai rocheux	8
2.2.3. Remblai en pâte cimenté.....	9
2.3 Description des remblais en pâte cimentés (RPC).....	11
2.3.1. Caractéristiques des différents composants du RPC.....	13

2.3.1.1.	Caractéristiques physique, chimique et minéralogique des résidus miniers	
		13
2.3.1.2.	Caractéristiques du liant hydraulique.....	15
2.3.1.3.	Caractéristiques de l'eau de mélange.....	19
2.3.2.	Propriétés mécaniques de RPC	20
2.3.2.1	Résistance à la compression uniaxiale	20
2.3.2.2	Résistance à la compression triaxiale	22
2.3.2.3	Résistance au cisaillement	23
2.3.3.	Modèles analytiques de prédiction de l'UCS des remblais miniers	24
2.4.	Généralités sur l'intelligence artificielle (IA)	28
2.4.1.	Historique de l'IA	28
2.4.2.	Définition de l'IA.....	29
2.4.2.1.	Apprentissage automatique (<i>Machine Learning</i>).....	30
2.4.2.2.	Apprentissage profond (<i>Deep Learning</i>)	34
2.5.	L'intelligence artificielle dans l'industrie minière.....	35
2.5.1.	Détection de défaillances dans les mines	35
2.5.2.	Détection de différents modes des défaillances dans les mines souterraines	
		36
2.5.3.	Prédiction de la résistance à la compression uniaxiale de RPC par l'IA ..	39
2.6.	Conclusion	41
CHAPITRE 3 MATÉRIELS ET MÉTHODES		42
3.1	Introduction.....	42
3.2	Matériels	42
3.2.1	Résidus miniers	42
3.2.2	Liant hydraulique	43
3.2.3	Eau de mélange	44
3.3	Démarche méthodologique	45
3.3.1	Caractérisation physique des résidus	46
3.3.2	Calculs des mélanges	48

3.3.3	Tests d'affaïssement.....	49
3.3.4	Préparation des éprouvettes de remblai	50
3.3.5	Essais de compression uniaxiale (UCS)	51
3.4	Méthodes intelligentes de prédiction de l'UCS	52
3.4.1	Collecte des données.....	52
3.4.2	Analyse et prétraitement des données	52
3.4.3	Critères de choix des modèles.....	55
3.4.4	Decision Tree (DT).....	58
3.4.5	Random Forest (RF)	59
3.4.6	Gradient Boosting Regressor (GBR)	60
3.4.7	eXtreme Gradient Boosting Regressor (XGBR).....	61
3.4.8	Réseau de neurones artificiels (ANN)	62
3.5	Conclusion	69
CHAPITRE 4 RÉSULTATS ET DISCUSSIONS.....		70
4.1	Introduction.....	70
4.2	Résultats expérimentaux	70
4.2.1	Distribution granulométrique des résidus	70
4.2.2	Essais de compression uniaxiale	72
4.2.3	Facteurs influençant l'UCS du remblai en pâte cimenté	74
4.2.3.1	Effet de type de liant et de sa proportion sur l'UCS	74
4.2.3.2	Effet des caractéristiques physique des résidus sur l'UCS	76
4.3	Résultats de programmation et développement	78
4.3.1	Analyse exploratoire des données (Exploratory data analysis - EDA).....	78
4.3.1.1	Distribution des données.....	78
4.3.1.2	Corrélations entre les données	85
4.3.1.3	Normalisation des données	88
4.3.2	Réglage des hyperparamètres des modèles.....	88
4.3.3	Performances des modèles	94
4.3.4	Validation de la prédiction.....	103

4.3.5 Déploiement du modèle performant pour la prédiction de l'UCS	109
CHAPITRE 5 CONCLUSIONS ET RECOMMANDATIONS	111
5.1 Conclusion	111
5.2 Retombées et Recommandations	113
RÉFÉRENCES BIBLIOGRAPHIQUES	114
ANNEXES	123

LISTE DES TABLEAUX

Tableau 2-1 Classification des résidus miniers canadiens (Bussière, 2007)	13
Tableau 2-2 La composition chimique des ciments et des ajouts minéraux	16
Tableau 2-3 Les phases minérales des ciments et des ajouts minéraux.....	16
Tableau 2-4 Valeurs des constantes d'ajustement polynomiales à utiliser avec Éq. (2.17c) (Sahi, 2016 ; Belem and Benzaazoua, 2015)	27
Tableau 2-5 Constantes pour le calcul des facteurs de pondération α_B et k (Belem, 2009)	28
Tableau 2-6 Synthèse des différences entre Machine Learning et Deep Learning.....	35
Tableau 3-1 Compositions chimiques des agents liants et des ajouts minéraux	44
Tableau 3-2 Caractéristiques physiques des agents liants et des ajouts minéraux	44
Tableau 4-1 Paramètres physiques des résidus	71
Tableau 4-2 Caractéristiques mécaniques des éprouvettes de RPC	73
Tableau 4-3 Description statistique des variables.....	84
Tableau 4-4 Hyperparamètres optimaux des modèles	90
Tableau 4-5 Algorithmes d'optimisation de Keras-TensorFlow	91
Tableau 4-6 Nombre des paramètres dans chaque couche du DNN.....	94
Tableau 4-7 Coefficient de corrélation (R) des modèles	105
Tableau 4-8 Comparaison avec d'autres résultats à vérifier	106
Tableau A-1 Feuille de calcul Excel pour calculer les masses des ingrédients du RPC	123
Tableau A-2 Exemple de plan de mélange utilisé au laboratoire pour préparer les mélanges de RPC	124

LISTE DES FIGURES

Figure 1-1 Principaux ingrédients d'un remblai minier cimenté	2
Figure 2-1 Les différents types de remblais miniers (Belem, 2022 ; Notes de cours).....	8
Figure 2-2 Différentes composantes du RPC (Belem and Benzaazoua, 2008b)	10
Figure 2-3 Résistance à la compression uniaxiale de RPC selon son rôle (Belem and Benzaazoua, 2008b).....	10
Figure 2-4 Schéma typique de la procédure complète de fabrication du remblai en pâte cimenté à l'usine (Belem and Benzaazoua, 2003a).....	11
Figure 2-5 Différents systèmes de distribution de remblais sous-terre (Belem and Benzaazoua, 2003a)	12
Figure 2-6 Mise en place du remblai : a) vide en cours de remblayage; b) schéma des composantes d'un vide remblayé (Belem and Benzaazoua, 2003a).....	12
Figure 2-7 Influence des particules fines ($d < 20 \mu\text{m}$) sur l'UCS (Fall et al., 2004)	14
Figure 2-8 Courbe typique d'un essai de compression uniaxiale (Belem, 2022 ; Notes de cours).....	21
Figure 2-9 Comparaison de la résistance mécanique des trois types de remblai utilisés dans l'industrie minière (Gauthier, 2004).....	21
Figure 2-10 Appareil triaxial (Robitaille et Tremblay, 1997).....	23
Figure 2-11 Courbe typique d'essais en compression triaxiale sur des remblais en pâte (Belem, 2022 ; Notes de cours).....	23
Figure 2-12 (a) Schéma d'une machine de cisaillement direct (McCarthy, 2010), (b) Enveloppe de rupture avec cohésion (Belem, 2022; Notes de cours).....	24
Figure 2-13 Les différents niveaux de l'intelligence artificielle	29
Figure 2-14 Notion de l'intelligence artificielle	30
Figure 2-15 Modèle simplifié en Machine Learning	31
Figure 2-16 Méthodologie d'implantation des algorithmes en Machine Learning	31
Figure 2-17 Différents types d'apprentissage automatique (ML)	32
Figure 2-18 Réseau de neurones : a) biologiques, b) artificiels (Djeriri, 2017)	34
Figure 2-19 Exemples d'éclatement des roches dans les galeries de mines souterraines (Jiang et al., 2010).....	37

Figure 2-20 Exemples d'incendies dans des tunnels et dans des galeries de mines souterraines (Zhang et al., 2021).....	39
Figure 3-1 Homogénéisation des résidus : a) résidu non homogénéisé; b) résidus en cours d'homogénéisation; c) résidu bien homogénéisé	43
Figure 3-2 Préparation des résidus pour la caractérisation physique a) agglomération des résidus; b) homogénéisation par la méthode de quatre points	43
Figure 3-3 Méthodologie de l'étude.....	46
Figure 3-4 Appareils de caractérisation physique des résidus : a) pycnomètre à hélium; b) granulomètre au laser Mastersizer 3000 de Malvern Panalytical.....	47
Figure 3-5 Préparation des mélanges : a) les ingrédients de RPC; b) mélangeur Hobart	49
Figure 3-6 Mesure de l'affaissement à l'aide de la méthode standard du cône d'Abrams; a) au laboratoire, b) principe de mesure de l'affaissement	50
Figure 3-7 Stockage des moules dans la chambre humide	51
Figure 3-8 Essai de compression uniaxiale : a) presse mécanique rigide MTS 10/GL ; (b) échantillon cassé après l'essai	52
Figure 3-9 Carte des algorithmes de la bibliothèque de Python Scikit-learn (Mathivet, 2021)	56
Figure 3-10 Structure d'un arbre de décision	58
Figure 3-11 Évolution de l'erreur en fonction de nombre des arbres	61
Figure 3-12 (a) Neurone biologique, (b) Neurone artificiel (Lacombe, 2018)	63
Figure 3-13 Réseau de neurones à rétropropagation vers l'arrière (Feed-Forward Back Propagation Network-FFBPN)	64
Figure 3-14 Fonction d'activation ReLU (Farhadi, 2017).....	67
Figure 3-15 Fonction d'activation Sigmoidale (Farhadi, 2017)	68
Figure 3-16 Fonction d'activation Softmax (Farhadi, 2017)	68
Figure 3-17 Fonction d'activation tangente hyperbolique (Farhadi, 2017)	69
Figure 4-1 Courbes granulométrique des résidus	71
Figure 4-2 Courbes contrainte-déformation pour le mélange 30GU/70Slag à 3% liant avec les résidus de LaRonde et à 28 jours de cure.....	72
Figure 4-3 Courbes contrainte-déformation pour le mélange 30GU/70Slag à 3% et avec les résidus de LaRonde et à 56 jours.....	73

Figure 4-4 Variation de l'UCS selon le type de liant GU/Slag	75
Figure 4-5 Variation de l'UCS en fonction de temps et pourcentage de liant avec les résidus de LaRonde.....	76
Figure 4-6 Variation de l'UCS selon le type de résidus	77
Figure 4-7 Variation de l'UCS en fonction de $P_{20\mu m}$ des résidus	78
Figure 4-8 Distribution des mélanges de RPC dans la base de données selon le type de résidus	80
Figure 4-9 Base de données a) avec valeurs manquantes b) sans valeurs manquantes ...	80
Figure 4-10 Distribution des variables.....	82
Figure 4-11 Densité de probabilité de l'UCS.....	83
Figure 4-12 Boîte à moustaches de l'UCS.....	83
Figure 4-13 Tendances entre les variables	86
Figure 4-14 Matrice de corrélations entre les variables	87
Figure 4-15 Densité de probabilité de l'UCS après normalisation	88
Figure 4-16 Boîte à moustaches de l'UCS après normalisation	88
Figure 4-17 Architecture du DNN	93
Figure 4-18 Description des couches du DNN	94
Figure 4-19 Comparaison sur la pente 1 :1 des prédictions des modèles; a) RF, b) GBR, c) XGBR, d) DNN	96
Figure 4-20 Schéma de processus de validation croisée	97
Figure 4-21 Courbe d'apprentissage des modèles; a) RF, b) GBR, c) XGBR	98
Figure 4-22 Évolution de la métrique du DNN (RMSE) en fonction de nombre d'itérations	99
Figure 4-23 Évolution de la fonction perte du DNN (MSE) en fonction de nombre d'itérations	99
Figure 4-24 Comparaison des valeurs de l'UCS dans l'ensemble de données du test et celles prédites par les modèles; a) RF, b) GBR, c) XGBR, d) DNN	100
Figure 4-25 Importances des variables sélectionnées par les modèles (a) GBR, (b) XGBR,	102
Figure 4-26 Comparaison des UCS prédites par les modèles et celles obtenues expérimentalement.....	103

Figure 4-27 Erreur de prédiction des modèles	104
Figure 4-28 Comparaison des performances des modèles	105
Figure 4-29 Interface de l'application web	109
Figure 4-30 Prédiction de l'UCS du RPC à base des résidus Upper beaver à l'aide du modèle GBR.....	110
Figure B-1 Évolution de l'UCS en fonction de la formulation de liant GU/Slag.....	125
Figure B-2 Évolution de l'UCS en fonction de la formulation de liant GU/Slag.....	126
Figure B-3 Évolution de l'UCS en fonction de la formulation de liant GU/Slag.....	126
Figure B-4 Évolution de l'UCS en fonction du B_w (%) et temps de cure.....	127
Figure B-5 Évolution de l'UCS en fonction du B_w (%) et temps de cure.....	128
Figure B-6 Évolution de l'UCS en fonction du B_w (%) et temps de cure.....	128

LISTES DES SIGLES ET ABRÉVIATIONS

ASTM	<i>American Society for Testing and Material</i> – Now ASTM International (Société américaine pour les essais et les matériaux)
DL	<i>Deep Learning</i> (Apprentissage profond)
DNN	<i>Deep Neural Network</i> (Réseau de neurones profonds)
FA-C	<i>Fly Ashes C</i> (cendres volantes, type C)
FA-F	<i>Fly Ashes F</i> (cendres volantes, type F)
GBR	<i>Gradient Boosting Regressor</i>
GU	<i>General Use Portland Cement</i> (Ciment Portland à usage général)
GGBFS	<i>Ground granulated blast furnace slag</i> (Laitier de haut fourneau granulé moulu ou broyé)
ML	<i>Machine Learning</i> (Apprentissage automatique)
RF	<i>Random Forest</i> (Forêt aléatoire)
RPC	Remblai en pâte cimenté
SVM	<i>Support Vector Machine</i>
UCS	<i>Uniaxial compressive strength</i> (Résistance à la compression uniaxiale)
XGBR	<i>eXtreme Gradient Boosting Regressor</i>

LISTE DES ANNEXES

Annexe A - Calcul des mélanges.....	135
Annexe B - Facteurs influençant l'UCS.....	137
Annexe C - Article de conférence.....	141

CHAPITRE 1 INTRODUCTION

1.1. Contexte de l'étude

Les ressources minières représentent des sources potentielles de revenus qui contribuent au développement de l'économie vu qu'elles produisent des métaux précieux et de base (or, fer, cuivre, zinc, plomb, nickel, etc.). Par ailleurs, elles produisent en contrepartie des quantités énormes des rejets solides (des roches stériles qui sont généralement entreposées en haldes et des résidus miniers qui sont entreposés dans des parcs à résidus). La gestion de ces rejets constitue un défi majeur pour une exploitation minière responsable, étant donné qu'ils ont provoqué des accidents et des désastres environnementaux majeurs. La méthode de déposition dans les parcs à résidus constitue le problème environnemental le plus critique et peut engendrer naturellement le drainage minier acide (DMA) par l'effet de l'oxydation de minerais sulfureux en présence de l'air et de l'eau (Aubé, 2004). De plus, l'accumulation de ces rejets en surface exige la construction de digues imperméables qui devient de plus en plus coûteuse. Cependant, la rupture de ces digues a engendré plusieurs dégâts matériels et humains (Bowker et Chambers, 2015). Une approche très utilisée dans les industries minières est le retour de ces résidus sous forme de remblai minier sous terre qui permet de réduire les impacts environnementaux et d'offrir un support secondaire pour assurer la stabilité de terrain (Belem and Benzaazoua, 2008a).

Le remblai minier est un matériau dédié au remplissage des excavations souterraines produites lors de l'extraction des minerais, il est constitué de résidus miniers ou de stériles, d'un agent liant composé généralement de ciment Portland et d'autres ajouts minéraux (Slag, cendre volante) et de l'eau de gâchage qui peut être eau de procédé ou eau de robinet (Figure 1-1). En effet, il existe principalement trois types de remblai minier : le remblai rocheux, le remblai hydraulique et le remblai en pâte cimenté et se distinguent par le type de rejets solides (roches stériles ou résidus miniers) et par l'existence ou non de liant hydraulique (Belem, 2022; notes de cours). Actuellement, le remblai en pâte cimenté (RPC) est l'un des plus utilisés dans divers mines dans le monde en vue de la diminution de la quantité des rejets miniers de moitié environ de la quantité de résidus sulfureux qui doit être entreposée en surface (Belem et al., 2000a; Benzaazoua et al., 1999a). Aussi grâce à ces propriétés mécaniques qui offrent une meilleure stabilité des chantiers ainsi qu'une sécurité des travailleurs (Belem and Benzaazoua, 2003a; Benzaazoua et al., 1999a; Mitchell, 1989). Malgré son usage courant, le RPC est un matériau très complexe et nécessite une

compréhension profonde de son évolution dès sa préparation jusqu'à son durcissement après sa mise en place sous terre (Belem et al., 2000b).

Dans le cadre de ce projet de recherche, il sera donc principalement question sur le comportement mécanique de RPC et plus précisément sa résistance à la compression uniaxiale (UCS). Diverses recherches ont été développées au cours de ces dernières décennies visant à prédire l'UCS par des modèles empiriques classiques qui restent encore complexes et ne répondent pas au besoin des mines.

Avec le progrès de développement des systèmes intelligents à nos jours, des modèles intelligents seront nécessaires pour prédire les propriétés des RPC.

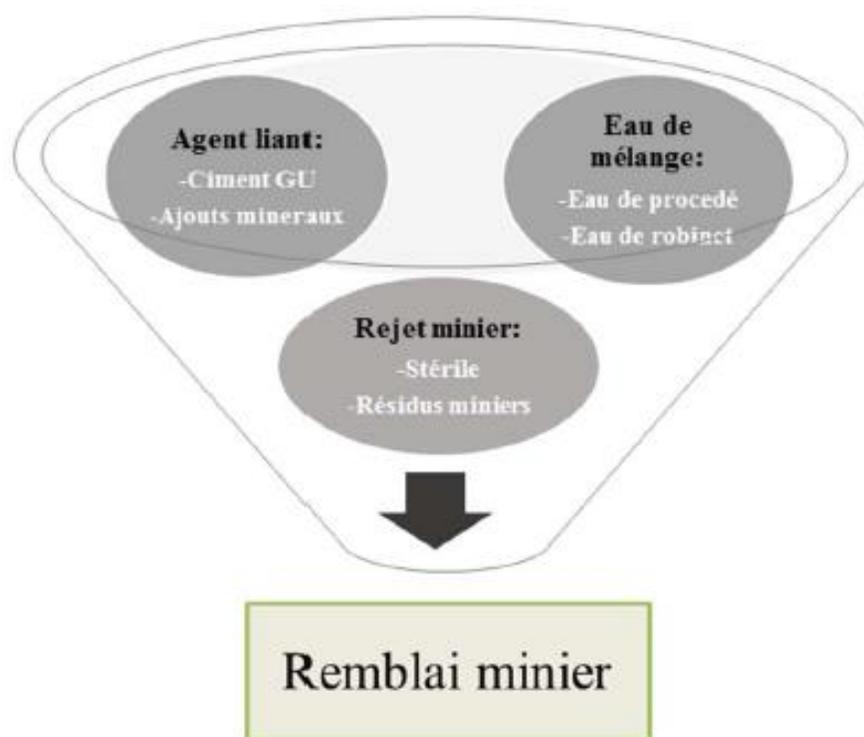


Figure 1-1 Principaux ingrédients d'un remblai minier cimenté

1.2. Problématique de l'étude

Les approches de l'intelligence artificielle (IA) telles que les réseaux de neurones artificiels (*Artificial Neural Network* - ANN), l'arbre de décision (*Decision Tree* - DT), la machine à vecteurs de support classique (SVM) et la machine à vecteurs de support des moindres carrés (*Least-Square Support Vector Machine* - LS-SVM) sont largement utilisés pour développer des modèles de

prédiction de la résistance mécanique des roches dans les contextes de l'extraction du pétrole et de l'exploitation minière (Asoodeh and Bagheripour, 2012; Mohamad et al., 2015). De nos jours, ces ANN dits formels ou neuromimétiques sont devenus les méthodes les plus populaires pour le développement de modèles de prédiction des propriétés mécaniques des roches dans le but de réduire les coûts opérationnels (Majdi and Rezaei, 2013; Momeni et al., 2015). Ces modèles aussi dits connexionnistes ont également été utilisés pour l'analyse de défaillances de puits de forage, la géomécanique des réservoirs, la stabilité des excavations souterraines ainsi que les caractéristiques des massifs rocheux (Asoodeh and Bagheripour, 2012; Khandelwal and Monjezi, 2013; Negara et al., 2017; Onalo, 2019).

Actuellement, malgré l'intensité des travaux de recherche visant à prédire les propriétés mécaniques (ex. la résistance à la compression simple ou *Unconfined compressive strength* - UCS) de divers matériaux à l'aide d'approches de l'intelligence artificielle, des travaux sur la prédiction de la résistance (UCS) des remblais miniers sont peu ou pas documentés dans la littérature.

Dans cette nouvelle ère de la 4^e révolution industrielle (Industrie 4.0), l'industrie minière a besoin de disposer d'outils performants d'aide à l'implémentation et/ou à l'optimisation des systèmes de remblayage souterrain. L'un de ces outils serait le développement de modèles de prédiction de la résistance à la compression des remblais en vue de la formulation de recettes de mélange optimales pour satisfaire aux exigences techniques de l'exploitation (propriétés mécaniques) tout en garantissant une utilisation rentable et sécuritaire de ce matériau. Les modèles empiriques simples ne répondent pas à ce besoin complexe. Voilà pourquoi il serait opportun de développer de tels modèles intelligents qui sont attendus par l'industrie minière et les firmes de génie-conseil.

1.3. Objectifs de l'étude

L'objectif principal de ce projet de recherche est de développer un outil de prédiction de la résistance à la compression simple ou uniaxiale (UCS, ou R_c , ou C_0 , ou σ_c) des remblais miniers en pâte cimentés par des algorithmes en *Machine Learning* (ML) et des algorithmes en *Deep Learning* (DL) ou apprentissage profond, en se basant sur des données réelles provenant de divers mines et données obtenues au laboratoire de l'URSTM de l'IRME à l'UQAT puis en comparant ces prédictions et en analysant les performances des modèles de prédiction. Afin d'atteindre cet objectif principal, les objectifs spécifiques ci-dessous doivent être atteints :

- Acquérir des données afin de construire une base de données riche ;
- Effectuer une analyse de sensibilité paramétrique de la base de données construite puis effectuer un prétraitement des données ;
- Développer, puis valider des modèles de ML et un réseau de neurones profond (DNN) sur la base de données construite et comparer leurs performances ;
- Développer une application web pour la mise en production du modèle prédictif.

1.4. Hypothèses de recherche

Dans cette étude, deux hypothèses ont été émises en lien avec les approches de l'IA :

- L'apprentissage automatique (*Machine Learning* – ML) permet de développer des modèles de prédiction robustes des propriétés mécaniques des **remblais en pâte cimentés (RPC)**,
- Les modèles d'apprentissage automatique (ML) ainsi que les réseaux de neurones artificiels (ANN) dépendent fortement de la quantité et de la qualité des données.

1.5. Démarche méthodologique de l'étude

La prédiction de l'UCS des RPC et la sélection de la recette optimale de ces derniers restent un défi pour toute l'industrie minière, ainsi que les firmes de génie-conseil, vu que les modèles empiriques de prédiction de l'UCS ne sont pas efficaces et il n'est pas trivial de développer des modèles analytiques (ou semi-analytiques) robustes et performants, car ils doivent être complexes et tenir compte de beaucoup de variables opérationnelles.

De plus, il n'est pas toujours aisé de recourir sans cesse aux travaux de laboratoire (optimisation des mélanges pour proposer la recette optimale après les essais de compression simple) qui peuvent devenir coûteux et qui prennent du temps (ex. de la pénurie de main-d'œuvre).

Par conséquent, le développement de modèles de prédiction de l'UCS des RPC par des approches de l'intelligence artificielle en se basant sur des données historiques, permettrait certainement de pouvoir sélectionner une recette optimale qui convienne à chaque système de remblayage.

Pour mener ce projet, tout d'abord une large base de données sera collectée, ses lignes représentent les mélanges de RPC et ses colonnes représentent différentes caractéristiques physiques, minéralogiques et chimiques des ingrédients de remblais. On trouvera également d'autres variables d'entrées comme les types de liant, à savoir le ciment Portland à usage général (GU), les laitiers de

haut fourneau (Slag), les cendres volantes (*Fly Ash* de types C et F), les proportions massiques de ciment/liant ($B_w\%$), la proportion ou le pourcentage solide ($C_w\%$), la quantité d'eau via la mesure de l'affaissement au cône d'Abrams S (en po ou mm) et le temps de cure t (en jour). La donnée de sortie (variable cible) est l'UCS (en kPa).

Les données seront recueillies à partir d'un ancien travail dans le cadre d'une maîtrise en génie minéral à l'IRME de l'UQAT afin de construire la base de données (Sahi, 2016). En effet, ces données comprennent des essais de compression uniaxiale sur 1010 éprouvettes de RPC préparées avec des résidus miniers échantillonnés à la mine d'or Casa Berardi. Les mélanges de RPC ont été préparés à un pourcentage solide unique $C_w\%$ de 75% et en prenant en compte plusieurs variables de mélanges : du ciment Portland à usage général (GU) comme ciment de base, des additions minérales telles que les cendres volantes (*Fly Ash* de types C et F), les laitiers de haut fourneau (Slag), différentes chimies des eaux de mélange telles que l'eau de robinet et des eaux sulfatées (avec 2500 et 5000 ppm). Par la suite, quatre classes d'agent liant ont été créées, à savoir le GU seul (liant témoin), le liant composé GU/Slag, le liant composé GU/FA-F et le liant composé GU/FA-C. Ces classes d'agent liant ont été utilisées pour la préparation de différentes recettes de mélanges de remblai en pâte cimenté avec différentes proportions de substitution de GU (variant de 30 à 90%) par les additions minérales choisies (Slag, FA-F et FA-C). Deux pourcentages massiques de liant ($B_w\%$) ont été utilisés, à savoir 4,5% et 7% (de la masse sèche des résidus miniers). Les temps de cure adoptés pour les essais de compression uniaxiale sont de 14, 28, 56 et 91 jours. Ainsi, après chaque temps de cure, les éprouvettes de remblai qui ont été fabriquées en triplicata ont été soumises à des essais de compression uniaxiale pour déterminer la résistance en compression uniaxiale (UCS).

D'autres données ont été collectées provenant des mines Goldex, LaRonde et Westwood. Le liant composé qui a été utilisé est généralement à base de GU/Slag, les eaux de procédés ont été utilisées comme eaux de mélanges, le pourcentage de solide varie entre 64% et 93%, le pourcentage de liant varie entre 1% et 9%, le temps de cure adopté varie de 1 jusqu'à 360 jours. À partir de toutes ces données, d'autres fiches techniques et des résultats de laboratoire, il sera possible de construire une riche base de données qui sera ensuite analysée et traitée pour pouvoir développer les modèles d'apprentissage automatique (ML) servant à prédire l'UCS des RPC. La démarche qui sera suivie pour réaliser ce projet de recherche sera bien détaillée dans le chapitre 3.

1.6. Structure du mémoire

Le présent mémoire est devisé en quatre chapitres, le *premier* étant un *chapitre* introductif qui présente le contexte général du projet.

Le *deuxième chapitre* porte sur la revue de littérature et présente la synthèse bibliographique des travaux antérieurs. Dans une première partie, il présente un aperçu sur les types de remblais miniers (ingrédients, transport, utilisation, etc.). Ensuite, une description détaillée sur les propriétés physiques, chimiques et mécaniques des remblais en pâte cimentés est présentée en décrivant les paramètres affectant la résistance à la compression uniaxiale (UCS) des RPC. Une deuxième partie synthétise les différents modèles empiriques et analytiques de prédiction de l'UCS. La dernière partie de ce chapitre décrit les notions de base sur l'intelligence artificielle (IA) en détaillant le concept de *Machine Learning* (ML) et *Deep Learning* (DL), ainsi que les différentes applications de l'intelligence artificielle dans l'industrie minière.

Le *troisième chapitre* présente la méthodologie générale adoptée dans ce projet, à savoir, les méthodes expérimentales de caractérisation physique des matériaux utilisés et les méthodes de développement d'un projet de ML. Les approches mathématiques des modèles de ML et le réseau de neurones artificiels (ANN) développés seront également bien détaillés dans ce chapitre.

Le *quatrième chapitre* présente les résultats obtenus dans cette étude et leur discussion.

Le mémoire se termine par des conclusions et des recommandations qui seront présentées dans le *cinquième chapitre*.

CHAPITRE 2 REVUE DE LITTÉRATURE

2.1. Introduction

Cette étude porte sur l'intégration du concept de l'intelligence artificielle dans le secteur minier afin de prédire la résistance à la compression uniaxiale des remblais miniers en pâte cimentés.

Bien que les nouvelles méthodes intelligentes soient relativement utilisées dans diverses industries (Industrie 4.0), les applications de ces méthodes au sein des industries minières sont peu développées. Plus spécifiquement au niveau de prédiction des propriétés des matériaux comme le remblai ou même la détection des défaillances des équipements et la détection des évènements sismiques. La nécessité de la recherche est donc justifiée d'une part, par l'inexactitude des modèles empiriques existants de prédiction de l'UCS des RPC et d'autre part, par l'énorme quantité de données existantes dans les mines qui sont non utilisables et qui seront très utiles pour développer des modèles intelligents.

Afin d'expliquer les différentes notions de ce projet, ce chapitre fait l'objet de l'état de l'art dont la première partie décrit brièvement les remblais miniers. La deuxième partie et la troisième partie seront dédiées, respectivement, à la présentation des modèles empiriques de prédiction de l'UCS, et à la description des notions d'apprentissage automatique (*Machine Learning* – ML) et apprentissage profond (*Deep Learning* - DL) qui vont servir à la prédiction intelligente de l'UCS de RPC.

2.2. Aperçu sur les remblais miniers

Comme il est mentionné avant, le remblayage est devenu une méthode la plus répandue, pour soutenir les structures dans les mines souterraines. En effet, les remblais miniers peuvent jouer soit le rôle de planchers de travail dont ils doivent avoir une bonne capacité portante afin de soutenir les équipements roulants, soit le rôle de piliers qui doivent avoir une capacité tenue (autoportante) afin d'éviter l'effondrement (Belem and Benzaazoua, 2003a). Ils peuvent également jouer le rôle de supports verticaux, de semelles de support ainsi que pour le stockage des rejets.

Il existe trois principaux types de remblai minier conventionnels qui sont le remblai hydraulique, le remblai rocheux et le remblai en pâte cimenté (Figure 2-1). La sélection du type de remblai

dépend de la méthode de minage et de la stratégie de gestion des rejets solides (Belem, 2022; *Notes de cours sur les remblais miniers*).

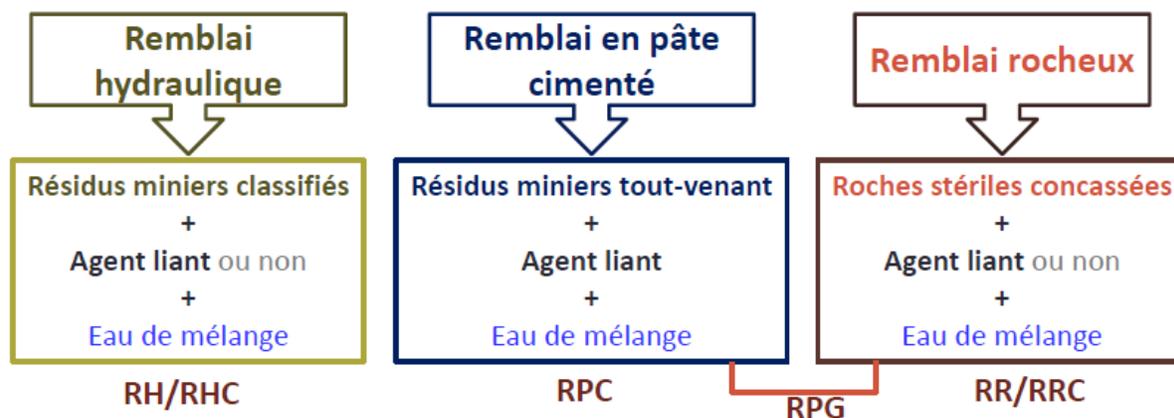


Figure 2-1 Les différents types de remblais miniers (Belem, 2022 ; *Notes de cours*)

2.2.1. Remblai hydraulique

Le remblai hydraulique est un remblai très fluide qui doit être drainé et il est constitué des rejets de concentrateurs généralement grano-classés par hydrocyclones, de l'eau et d'un agent liant (si nécessaire). Autrefois c'était du sable qui remplaçait les rejets grano-classés. Ce type de remblai minier a un pourcentage de solides $C_w\%$ (ou densité de pulpe $P_m\%$) compris entre 60% et 70%. Afin de faciliter leur drainage après leur mise en place, le pourcentage des « particules fines » (c'est-à-dire ayant un diamètre moyen $d < 10 \mu m$) doit être au maximum de 20%. Le remblai hydraulique est transporté par gravité vers les chantiers par pipelines et sa mise en place nécessite toujours l'installation de barricades hydrostatiques capables de le retenir en place. Pour ce faire, un système de drains et de tours de décantation est toujours installé (Belem, 2022; *Notes de cours sur les remblais miniers*).

2.2.2. Remblai rocheux

Le remblai rocheux est un mélange quasiment sec constitué des roches stériles (tout-venant qui est concassé lors des opérations de dynamitage normales) sans (remblai rocheux – RR) ou avec l'ajout d'un coulis d'un agent liant pour aider à la cimentation (remblai rocheux cimenté – RRC). Pour le RRC, le coulis est préparé en mélangeant de l'eau et un agent liant (ciment Portland avec ou sans addition minérale comme les cendres volantes ou les scories) dans un ratio eau/ciment (E/C) pouvant varier entre 0,8 et 1,2. Selon la résistance visée, le coulis peut être ajouté avant, pendant

ou après le déversement des roches stériles dans les chantiers. Afin de développer une résistance raisonnable, le RRC doit contenir un pourcentage de « particules fines » ($d < 10$ mm) variant entre 25% et 40%. Les roches stériles peuvent être transportées soit depuis la surface à l'aide de camions ou de convoyeurs, soit sous terre à l'aide de chargeuses-navettes jusqu'au point de déversement dans les chantiers. Le remblai rocheux ne nécessite pas la mise en place d'un système de drainage, mais il est indispensable de contrôler le phénomène de ségrégation des particules par l'installation des barricades simples pour empêcher la projection de fragments rocheux lors du déversement dans le chantier. C'est donc plus un ouvrage construit pour la sécurité des travailleurs (Belem 2022, *Notes de cours sur les remblais miniers*).

2.2.3. Remblai en pâte cimenté

Le remblai en pâte cimenté (RPC) est un mélange des rejets de concentrateur (résidus miniers) tout-venant, de l'eau et d'un agent liant hydraulique (à un pourcentage massique variant généralement entre 2 et 10% selon la résistance visée) (Figure 2-2). Le RPC est préparé à un pourcentage massique de solides $C_w\%$ qui peut varier entre 70 et 85% selon la densité relative des résidus et suivant le mode de transport par pipelines (pompage, gravité ou leur combinaison). Il est admis que si les résidus miniers contenaient au moins 15% de « particules fines » (c.-à-d. ayant un diamètre moyen $d < 20$ μm), l'écoulement du RPC entraînerait moins d'usure des tuyaux par abrasion. Dans la pratique de l'industrie minière, il a été constaté que la fluidité du RPC, qui garantirait un écoulement laminaire et lisse en pipelines vers les chantiers à remblayer, devra correspondre à une consistance mesurée par l'affaissement (ou *slump*) au cône d'Abrams standard qui serait compris entre 152,4 mm (6 pouces) et 254 mm ou 10 pouces (Belem 2022, *Notes de cours sur les remblais miniers*). La résistance de remblai cimenté dépend de son rôle désigné sous terre. La Figure 2-3 décrit les différentes résistances du remblai selon sa fonction.

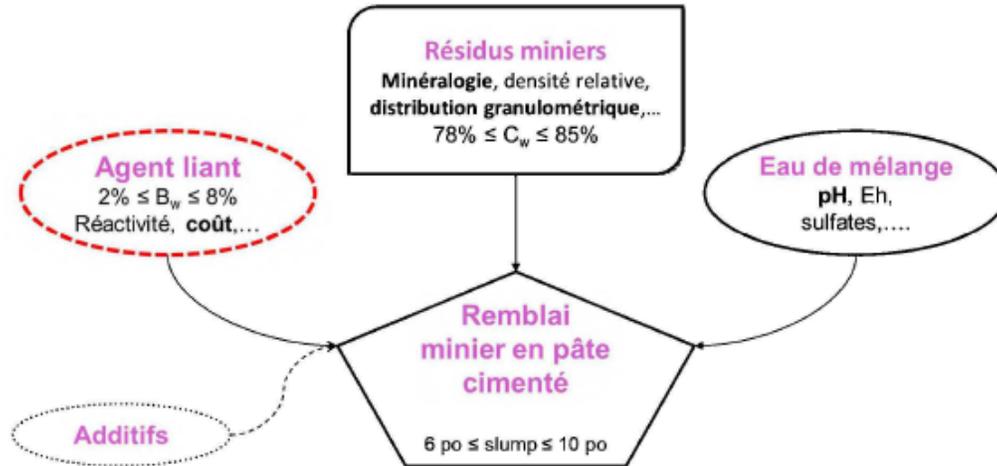


Figure 2-2 Différentes composantes du RPC (Belem and Benzaazoua, 2008b)

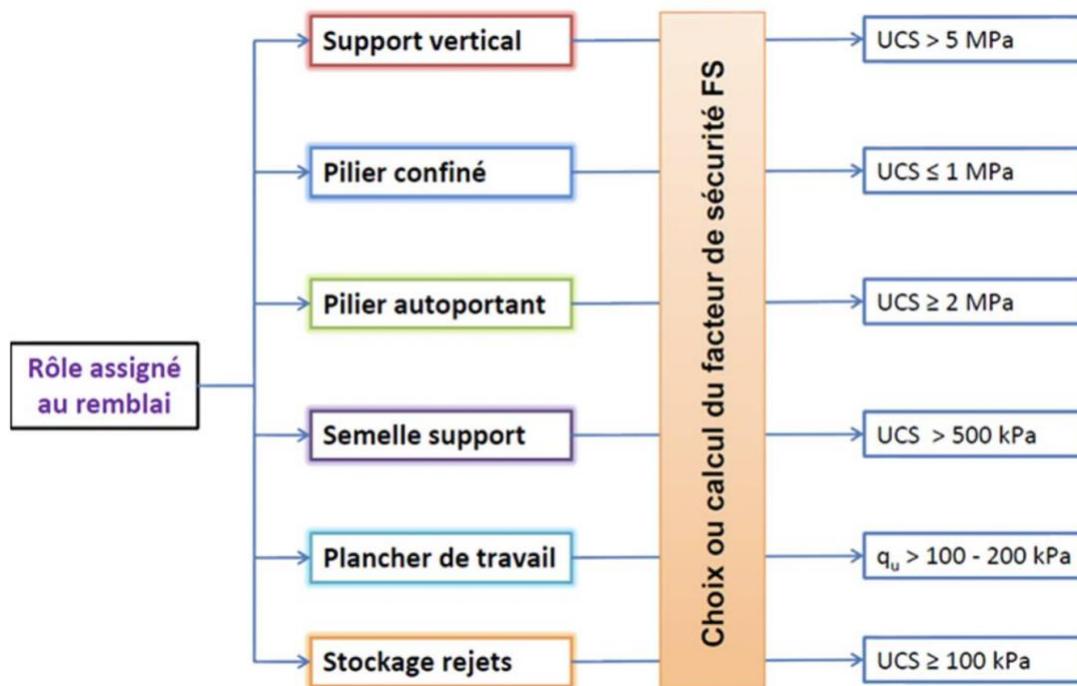


Figure 2-3 Besoin en résistance à la compression uniaxiale des RPC selon leur rôle (Belem and Benzaazoua, 2008b)

2.3 Description des remblais en pâte cimentés (RPC)

Afin d'étudier le comportement des RPC, il est crucial de comprendre les phases de son évolution dès sa préparation, son transport, jusqu'à sa mise en place. En effet, la procédure de fabrication du remblai cimenté dans l'usine est résumée dans la Figure 2-4. Les deux premières étapes consistent, en premier lieu, à ramener le pourcentage de solides des résidus humides (pulpe) de 30% à 60% par l'épaississement à l'aide d'un épaississeur, en deuxième lieu de 60% jusqu'à un pourcentage compris entre 70% et 82% par la filtration des résidus épaissis. Après avoir traité les résidus, le RPC est fabriqué par l'ajout de liant hydraulique et l'eau de malaxage pour atteindre la consistance visée pour son transport. Finalement, après un certain temps de malaxage, le remblai obtenu est acheminé sous terre par un réseau de pipelines (Belem and Benzaazoua, 2003b).

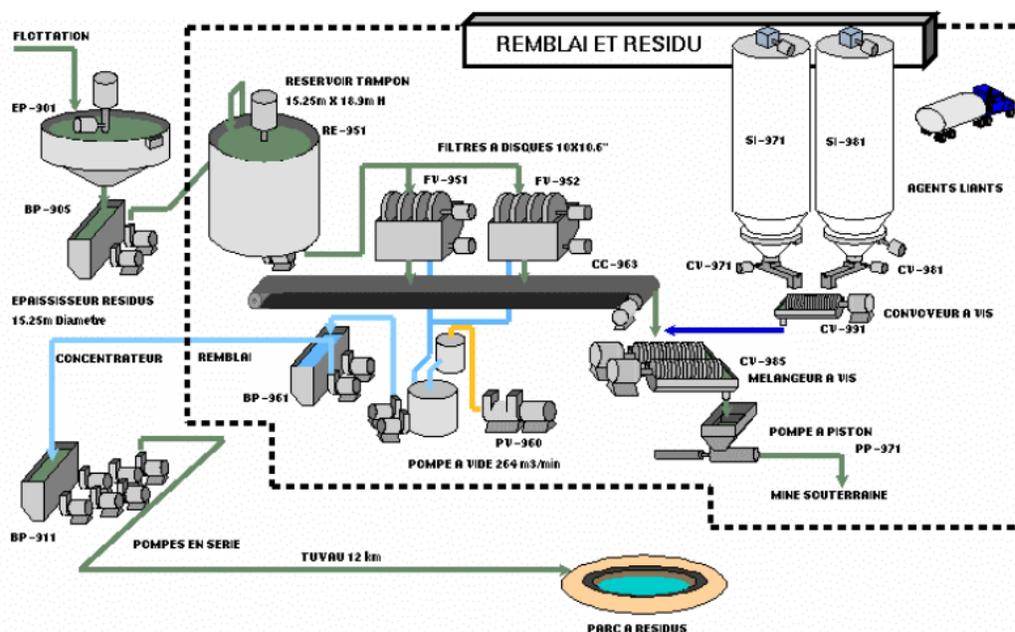


Figure 2-4 Schéma typique de la procédure complète de fabrication du remblai en pâte cimenté à l'usine (Belem and Benzaazoua, 2003a)

En ce qui concerne le transport du RPC, il pourra se faire soit par un système gravitaire soit par un système couplé avec des pompes à piston (système par pompage/gravité, système par gravité/pompage) tout dépend de ses propriétés rhéologiques et aussi du positionnement de l'usine de RPC par rapport aux chantiers à remblayer (Figure 2-5). Dans le plan pratique, il est difficile de contrôler ces propriétés, c'est pour cela l'essai au cône d'Abrams standard qui est le plus utilisé afin de contrôler la consistance du RPC. Lorsque l'affaissement souhaité est atteint, la pâte sera

envoyée à travers un réseau de pipelines sous terre. Lors de son écoulement laminaire, des pertes de charge se créent c'est donc des modèles rhéologiques ont été pris en compte pour assurer un bon design de système de transport (Belem and Benzaazoua, 2003b).

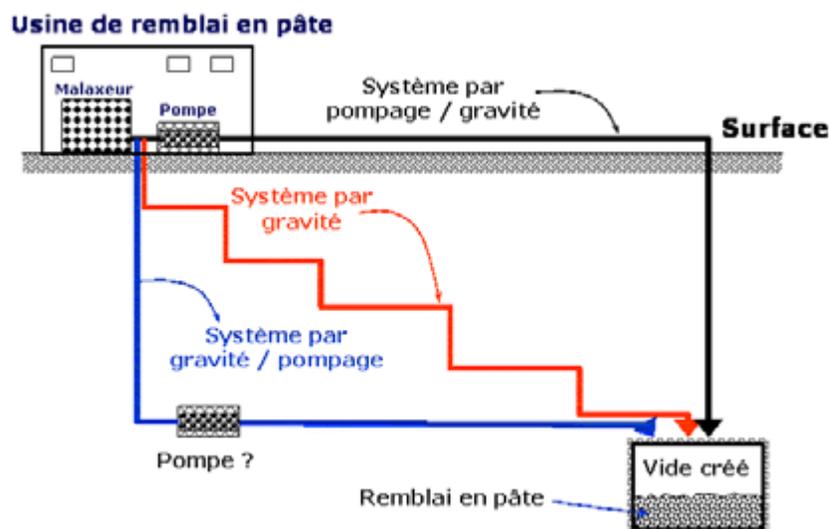


Figure 2-5 Différents systèmes de distribution des remblais sous terre (Belem and Benzaazoua, 2003a)

Une fois mis en place (Figure 2-6), le développement de la résistance mécanique de RPC dépendra de plusieurs facteurs d'une part par le phénomène d'hydratation et les caractéristiques physiques, chimiques et minéralogiques de ses constituants et d'autre part, par plusieurs facteurs microscopiques : le drainage naturel de l'eau, la consolidation de la masse de remblai, la pression sur la barricade ainsi que l'existence ou non de l'effet d'arche (Belem and Benzaazoua, 2003b).

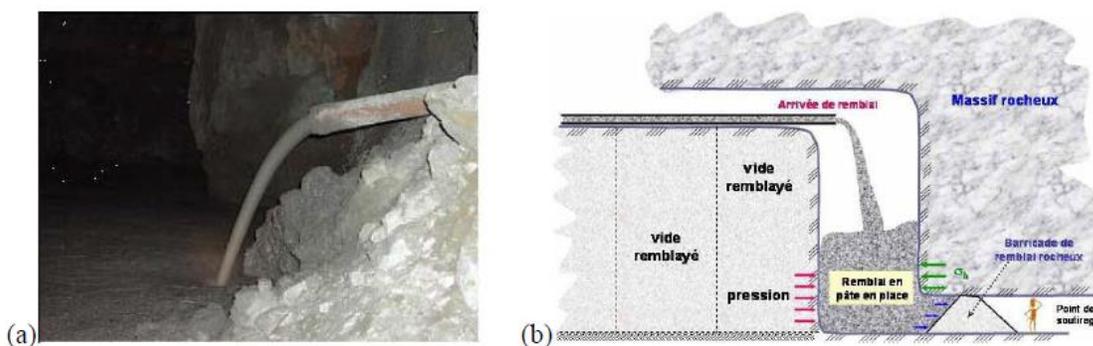


Figure 2-6 Mise en place du remblai : a) vide en cours de remblayage; b) schéma des composants d'un vide remblayé (Belem and Benzaazoua, 2003a)

2.3.1. Caractéristiques des différents composants du RPC

2.3.1.1. Caractéristiques physique, chimique et minéralogique des résidus miniers

Après l'extraction des minerais, ces derniers subissent des traitements à la fin desquelles on obtient les résidus miniers qui seront acheminés soit vers un parc à résidus soit vers l'usine de remblai. Les résidus représentent le matériau principal pour fabriquer le remblai en pâte. Ils remplacent les granulats (sable et gravier) dans le cas de béton. Cependant, les caractéristiques du RPC dépendent fortement par les caractéristiques physiques et minéralogiques des résidus qui diffèrent d'une mine à une autre. Parmi ces caractéristiques, on cite principalement :

- ***Distribution granulométrique***

La distribution granulométrique des résidus est l'un des principaux facteurs contribuant au développement de la résistance du remblai. En effet, les résidus miniers se caractérisent par une granulométrie similaire à celle du sable fin. Pour obtenir un RPC optimal, les résidus doivent avoir une distribution granulométrique étalée dont le coefficient d'uniformité C_U est supérieure à 2 et le coefficient de courbure C_C compris entre 1 et 3. Belem & Benzaazoua (2003) ont constaté que les remblais cimentés contenant des résidus bien classés ont une résistance à la compression plus importante que les remblais contenant des résidus mal classés (distribution granulométrique uniforme). Les particules fines ($d < 20 \mu\text{m}$) présentes dans les résidus exercent une influence néfaste sur le développement de la résistance de RPC (Figure 2-7). Plus les résidus utilisés sont fins, plus la demande en eau sera élevée et donc plus la porosité globale du remblai est élevée, ce qui résulte d'une perte de résistance (Fall et al., 2005). Il a été recommandé que les résidus contiennent au moins 15% de particules fines de moins de $20 \mu\text{m}$ de diamètre pour obtenir de bonnes résistances de remblais cimentés (Landriault, 1995; Tenbergen, 2000). Selon Bussière, (2007), la classification des résidus des mines canadiennes est illustrée dans le tableau suivant :

Tableau 2-1 Classification des résidus miniers canadiens (Bussière, 2007)

	D₁₀ (mm)	D₆₀ (mm)	C_U	P_{20μm}	P_{80μm}
Résidus hors Québec	0.001 - 0.004	0.01 - 0.05	8 - 18	5 % - 14 %	70% - 97 %
Résidus au Québec	0.0009 - 0.006	0.01 - 0.08	10 - 30	4% - 20%	60% - 100%

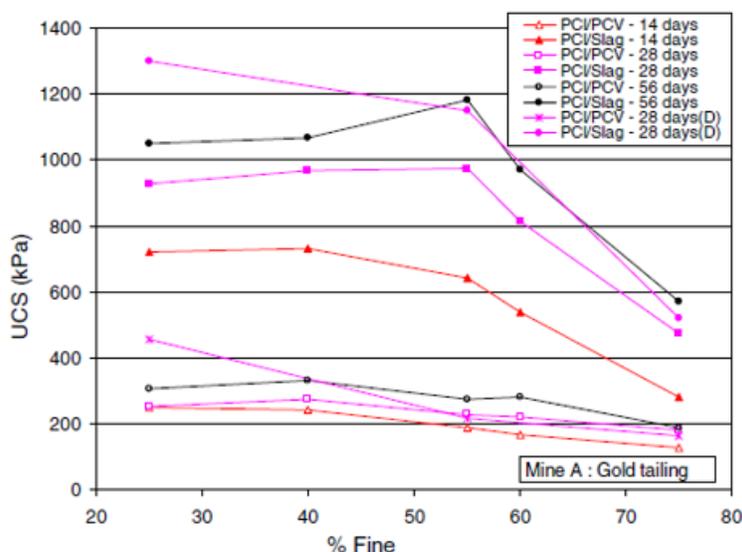


Figure 2-7 Influence des particules fines ($d < 20 \mu\text{m}$) sur l'UCS (Fall et al., 2004)

- **Densité relative (D_R ou G_s)**

La densité relative est une propriété physique importante pour la fabrication du remblai. Elle s'exprime par l'expression suivante :

$$D_R = G_s = \frac{\rho_s}{\rho_w} \quad (2-1)$$

Avec, ρ_s = la masse volumique des grains solides et ρ_w = la masse volumique de l'eau.

La valeur de la densité relative des résidus miniers varie entre 2.6 et 4.5 (Bussière, 2007). Elle dépend fortement par la teneur en sulfures présent dans les résidus (Fall and Benzaazoua, 2003). Fall et al. (2005) ont observé que l'augmentation de la densité des résidus était généralement accompagnée d'une valeur plus élevée de l'UCS du remblai en pâte. Ceci s'explique par le fait que la consommation en liant augmentait en volume du fait du dosage massique constant du pourcentage massique de liant (Belem & Benzaazoua, 2008).

- **Teneur en minéraux sulfureux**

La présence des sulfures dans les résidus miniers pourrait conditionner la performance mécanique du RPC. D'une part, une teneur élevée en minéraux sulfureux rend les résidus très denses et cela affectera le volume du liant par rapport à un dosage massique constant. D'autre part, si ces sulfures s'oxydaient il y'aurait libération de sulfates dissous et de l'acidité qui pourraient inhiber l'hydratation du liant hydraulique ou même provoquer l'attaque sulfatique qui entraînerait une

baisse de la résistance. Toutefois, en présence d'un liant au laitier (slag), ces sulfates pourraient contribuer à la formation de l'ettringite secondaire qui participera à l'acquisition et à l'amélioration de la résistance du remblai à court terme et à long terme. En effet, lorsque ces minéraux sulfureux amorcent leur oxydation à la suite de leur contact avec l'air et l'eau pour former des minéraux sulfatés (ex. : ettringite - AFt, gypse, et monosulfoaluminate - AFm). Ces derniers vont colmater les vides existant dans le remblai ; ce qui va améliorer la résistance du remblai au début de la cure. Toutefois, à long terme, la résistance pourrait chuter progressivement si les minéraux sulfatés formés sont gonflantes et génèrent dans le remblai des contraintes de cristallisation élevées qui vont engendrer des microfissures dans la matrice du RPC (Fall and Benzaazoua, 2005a). Diverses études ont tenté d'expliquer l'effet des sulfates dissous sur le développement de la résistance des RPC (Benzaazoua et al., 2002, 1999b; Bernier et al., 1999).

2.3.1.2. Caractéristiques du liant hydraulique

Le liant hydraulique est un matériau indispensable pour la fabrication du remblai en pâte cimenté, c'est l'élément responsable pour le développement de la résistance du RPC. Plusieurs études ont montré que l'augmentation de la proportion de liant améliore considérablement la résistance du remblai, de mortier et de bétons (Amriou et al., 2019; Belem et al., 2000b; Zajac, 2007). Un agent liant c'est un liant composé d'un ciment hydraulique (généralement ciment Portland) et un ou plusieurs des ajouts minéraux (laitier, cendre volante, carbonates de calcium, fumée de silice, etc.).

▪ Ciment Portland

Il faut noter que le ciment Portland est le constituant principal d'un agent liant. Sa fabrication commence par la préparation de cru (80% de calcaire et 20% d'argile qui apportent les principaux oxydes) puis la cuisson dans un four rotatif à 1450°C afin d'obtenir le clinker. Le ciment est obtenu à la fin par le broyage du clinker, et l'ajout de 5% de gypse et d'autres ajouts minéraux, le cas échéant. La composition chimique et les phases minérales des ciments et des ajouts minéraux (Tableaux 2-2 et 2-3) représentent les caractéristiques les plus importantes responsables de la réaction d'hydratation. Le ciment Portland (clinker) contient principalement de la silice (SiO_2), de la chaux (CaO), de l'alumine (Al_2O_3) et de l'oxyde de fer (Fe_2O_3), qui formeront les quatre phases minérales principales : le silicate tricalcique ou *alite* (C_3S), le silicate dicalcique ou *belite* (C_2S), l'aluminate tricalcique ou *celite* (C_3A) et le ferroaluminate tétracalcique ou *felite* (C_4AF). Le pourcentage de ces phases minérales diffèrent d'un type de ciment Portland à l'autre. En effet,

du fait que le ciment Portland de type I ou GU possède la teneur en C₃A la plus élevée de tous les autres types de ciment Portland (≈10-12%), ceci le rendrait vulnérable à la présence de sulfates dissous qui pourraient entraîner la formation de minéraux secondaires expansifs tels que l'ettringite et le gypse conduisant ainsi à l'attaque sulfatique. Ce phénomène d'attaque sulfatique a été confirmé dans les travaux de Fall and Benzaazoua (2005b) sur les remblais en pâte cimentés incorporant des sulfates dissous. Au contraire, le ciment Portland de type V ou HS, connu pour sa forte résistance aux sulfates (≈ 4% de C₃A), permettait aux remblais en pâte cimentés de résister à l'attaque sulfatique. En comparant ces deux types de ciment Portland (GU et HS) au niveau de développement de résistance à court et à long terme, le ciment Portland GU (type I) développait des résistances élevées à court terme qui commencent à chuter à partir de 28 jours (attaque sulfatique). Au contraire, le ciment Portland HS (type V) a permis aux remblais de développer de bonnes résistances à partir de 56 jours (Fall and Benzaazoua, 2005b).

Tableau 2-2 Composition chimique des ciments et des ajouts minéraux

Type de ciment	SiO ₂ (wt%)	Al ₂ O ₃ (wt%)	Fe ₂ O ₃ (wt%)	CaO (wt%)	MgO (wt%)	SO ₃ (wt%)	Alkali (wt%)
Type I (GU)	20.5	5.4	2.6	63.9	2.1	1-4.5	0.2-1.3
Type II (MH & MS)	21.2	4.6	3.5	63.8	2.1	1-4.5	0.2-1.3
Type III (HE)	20.6	4.9	2.8	63.4	2.2	1-4.5	0.2-1.3
Type IV (LH)	22.2	4.6	5	62.5	1.9	1-4.5	0.2-1.3
Type V (HS)	21.9	3.6	4.2	63.8	2.2	1-4.5	0.2-1.3
Class F fly ash (FA-F)	52	23	11	5	2	0.8	2.3
Class C fly ash (FA-C)	35	18	6	21	5	4.1	6.3
Blast furnace slag (GGBFS)	36	10	0.5	39	512	0.6-2	0.6
Silica fume (SF)	90	0.4	0.4	1.6	1.7	0.4	2

Tableau 2-3 Composition des phases minérales des ciments Portland

Type de ciment Portland	Composition moyenne potentielle du composé (%)				Finesse de Blaine (m ² /kg)
	C ₃ S	C ₂ S	C ₃ A	C ₄ AF	
GU (I)	54	18	10	8	369
MS, MH (II)	55	19	6	11	377
HE (III)	55	17	9	8	548
LH (IV)	42	32	4	15	340
HS (V)	54	22	4	13	373
White	63	18	10	1	482

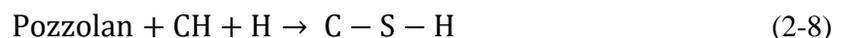
La prise et le durcissement de ciment est dû principalement à la réaction l'hydratation entre l'eau et le ciment. Le début de prise correspond à l'augmentation brutale de la viscosité de la pâte ciment et l'élévation de la température et la fin de prise correspond à la transformation progressive et régulière de la pâte en un bloc rigide ce qui représente le début de durcissement. L'hydratation de ciment se fait selon les réactions des phases minérales suivantes :



La première réaction (2-2) représente l'hydratation et le durcissement rapide de silicate tricalcique (C_3S) qui est responsable de la prise initiale et le développement de la résistance à court terme, la deuxième (2-3) correspond à l'hydratation et durcissement lent de silicate dicalcique (C_2S) qui contribue à l'augmentation de résistance à long terme. La réaction exothermique (2-4) se fait lors du contact de l'aluminate tricalcique (C_3A) avec l'eau. La réaction chimique (2-5) du ferroaluminate tétracalcique (C_4AF) ne joue pas un rôle assez significatif sur l'hydratation.

▪ *Ajouts minéraux*

Les ajouts minéraux sont connus par leur faible capacité de cimentation et par leur effet pouzzolanique qui améliore la résistance à la compression uniaxiale du RPC par la consommation de la portlandite (CH) pour former des silicates de calcium hydratés ou C-S-H. La réaction pouzzolanique (2-8) est plus lente que celle de l'hydratation du clinker, et c'est pour cette raison que l'effet des ajouts minéraux est plus remarquable à long terme (Belem, 2022; *notes de cours*).



Les ajouts minéraux les plus couramment utilisés dans la formulation des remblais en pâte cimentés sont les suivants :

Cendres volantes (fly ash)

Les cendres volantes sont obtenues par la combustion, le broyage et puis la calcination du charbon dans des centrales thermiques à une température de 1200°C et plus. Elles sont constituées essentiellement de silicium, d'aluminium et d'oxyde de fer (Archibald et al., 1998). Selon la norme américaine ASTM, on trouve deux types des cendres volantes :

- *Les cendres volantes de type C* : provenant de la combustion du charbon de lignite, ils contiennent la silice réactive SiO_2 , l'alumine Al_2O_3 et la chaux (Tariq, 2012). Ce type de cendres volantes se caractérise par sa forte teneur en chaux (CaO) qui varie entre 15% et 30% et par sa pauvreté en fer. Leurs propriétés pouzzolaniques ont l'aptitude à neutraliser le potentiel acide des résidus miniers vu qu'ils présentent une forte teneur en calcium (Tariq, 2012).
- *Les cendres volantes de type F* : provenant de la combustion du charbon anthracite, ils contiennent la silice SiO_2 et l'alumine Al_2O_3 . Ce type de cendre volante se caractérise par sa faible teneur en chaux (CaO) qui est moins de 5%.

Les cendres volantes de type F sont plus résistantes à l'attaque sulfatique que les cendres volantes de type C, mais un activateur sera nécessaire pour sa cimentation.

Divers chercheurs ont évalué l'effet de substitution d'une proportion de ciment Portland par les cendres volantes. Hassani et al. (2001) ont étudié l'effet des sulfates sur la stabilité du RPC en comparant le comportement du remblai fait à base de ciment Portland seul et celui fait à base de ciment composé de ciment Portland et des cendres volantes de type C. Les résultats montrent que la fabrication du remblai avec le ciment Portland seul n'est pas adéquate pour garantir une stabilité à long terme. Alors que le ciment composé de cendres volantes de type C a développé de bonnes résistances à long terme. Benzaazoua et al. (1999a) ont montré que la substitution d'une proportion de ciment Portland par des cendres volantes de type F a amélioré la résistance des RPC à l'attaque sulfatique.

Laitiers de hauts fourneaux (Ground Granulated Blast-Furnace Slag - GGBFS)

Les laitiers (ou scories) sont issus des procédés pyrométallurgiques utilisés dans les industries de production de cuivre, de zinc, de fer, et de plomb. Ils sont élaborés à l'état liquide, en même temps que le fer dans des hauts fourneaux à haute température (entre 1350 et 1550°C), puis ils sont

refroidis rapidement dans l'eau et broyés pour obtenir une texture fine. Ils sont constitués principalement de la chaux, de la silice et de l'alumine et d'autres (Bouzoubaâ and Foo, 2004).

Afin d'être plus réactif lors de sa substitution partielle dans le ciment, le laitier doit être très fin. Il peut remplacer de grandes proportions de ciment selon sa finesse et il développe des résistances meilleures. En outre, les paramètres qui définissent les propriétés hydrauliques du laitier sont sa composition chimique et son état vitreux (Bouzoubaâ and Foo, 2004).

Diverses recherches ont montré que la substitution partielle de ciment Portland par la Slag dans la fabrication des remblais miniers en pâtes cimentées est prometteuse. Belem et al. (2000a) ont évalué le comportement mécanique des RPC à court et à long terme par l'utilisation des résidus provenant de deux mines polymétalliques et par différents types de liant à base de ciment Portland, des scories et des cendres volantes. Les résultats montrent que les remblais miniers fabriqués avec le liant à base de scories ont développé de meilleures résistances à la compression. Benzaazoua et al. (2002) ont étudié l'effet de liant composé à base de ciment Portland, laitiers et cendres volantes sur les résidus sulfureux (différents teneurs en sulfures). Il a été souligné que pour les résidus à haute teneur en sulfure, les liants à base de laitier n'étaient pas efficaces. Cependant, ils ont donné de meilleures résistances pour les résidus faiblement et moyennement sulfurés. Ouellet et al. (2007) ont évalué l'influence de la qualité de l'eau, le type et la proportion de liant et le temps de cure sur la microstructure des RPC par la préparation de différents échantillons faits à base de différent type de liant (100GU, 20GU/80Slag et 70GU/30Fly Ash). Les principaux résultats montrent que le laitier a un impact plus important sur le raffinement des pores dans les pâtes de ciment que les autres liants, ce qui lui a permis de développer les résistances les plus élevées.

2.3.1.3. Caractéristiques de l'eau de mélange

L'eau de gâchage peut être eau de procédé ou eau naturelle. Elle est constituée de l'eau résiduelle dans les résidus et l'eau ajoutée pour fabriquer le remblai et pour atteindre l'affaissement voulu. Sa quantité et sa composition chimique, plus particulièrement la teneur en sulfate a un effet très significatif sur le comportement mécanique de RPC. En effet, la présence des sulfates dans l'eau de gâchage retarde l'hydratation de ciment. Sahi (2016) a étudié l'effet des eaux sulfatées sur l'UCS des RPC par la fabrication de différents mélanges avec plusieurs types de liant composé (GU, Slag, Fly ash) ainsi qu'avec trois types d'eaux (eau de robinet, deux eaux sulfatées: 2500 et 5000 ppm). Les résultats montrent que les mélanges de remblais réalisés à base d'eau de robinet ont pu

développer les meilleures résistances, tandis que ceux réalisés avec les eaux sulfatées ont eu les plus faibles résistances. Il a été conclu également que la résistance à l'attaque sulfatique s'améliore avec l'augmentation de la quantité de la Slag dans le liant. Ouellet et al. (2007) ont étudié l'influence de la chimie des eaux sur la microstructure et la résistance à la compression uniaxiale des RPC. Ils ont utilisé trois types d'eaux (eau désionisée, deux eaux sulfatées: 4613 ppm et 7549 ppm) et trois types de liants (ciment Portland de type 10 ou GU, un liant composé 20GU/80Slag et un liant composé 70GU/30Fly Ash) avec un pourcentage de 5%. Les résultats montrent que les meilleures résistances à la compression uniaxiale ont été obtenues pour des mélanges de RPC faits avec des eaux sulfatées et avec un liant composé contient de Slag. Tandis que ceux fait à base d'eaux sulfatées et avec un liant à base de GU seul (ou un liant composé contenant des cendres volantes) ont eu de faibles résistances et presque similaires.

2.3.2. Propriétés mécaniques de RPC

La connaissance, et peut-être le contrôle, des propriétés mécaniques des remblais miniers, et plus spécifiquement du RPC qui est le plus utilisé dans l'industrie minière, est indispensable plus particulièrement durant les phases de préfaisabilité et de mise en œuvre d'un système de remblayage souterrain. Ces propriétés mécaniques sont principalement :

- a) les paramètres élastiques déduits à partir de la courbe contrainte-déformation obtenue lors d'un essai à la compression uniaxiale à savoir le module de Young ou de déformation E et le coefficient de poisson (ν), ainsi que la résistance à la compression uniaxiale (*uniaxial/unconfined compressive strength* - UCS), ;
- b) les paramètres intrinsèques déterminés à l'aide d'essais de compression triaxiale qui sont la cohésion drainée (c') et l'angle de frottement interne effectif (ϕ');
- c) la résistance à la traction indirecte du remblai (σ_T) obtenue à l'aide d'essais de fendage diamétral ou Brésiliens;

2.3.2.1 Résistance à la compression uniaxiale

Les essais à la compression uniaxiale permettent de déterminer la résistance à la compression uniaxiale (UCS) en appliquant une charge axiale jusqu'à la rupture. La contrainte axiale correspondant à cette charge maximale à la rupture représente la résistance en compression uniaxiale (R_c , q_u , UCS ou C_0) du remblai cimenté (Benzazoua et al., 2005). Cette résistance est le

paramètre clé utilisé par l'industrie minière pour l'analyse du comportement mécanique des remblais miniers. La Figure 2-8 représente la courbe typique (contrainte-déformation) obtenue lors d'un essai de compression uniaxiale sur un échantillon de RPC qui permet de déterminer la résistance à la compression uniaxiale de ce dernier (pic de la courbe), ainsi que le module de Young (E) qui représente la pente de la partie linéaire de la courbe.

En comparant le comportement mécanique des remblais miniers, la Figure 2-9 présente l'évolution comparative (approximative) de l'UCS des trois principaux types de remblai minier utilisés. On peut constater que les plus grandes résistances mécaniques sont obtenues avec les remblais rocheux cimentés (RRC), suivi des RPC et des remblais hydrauliques cimentés.

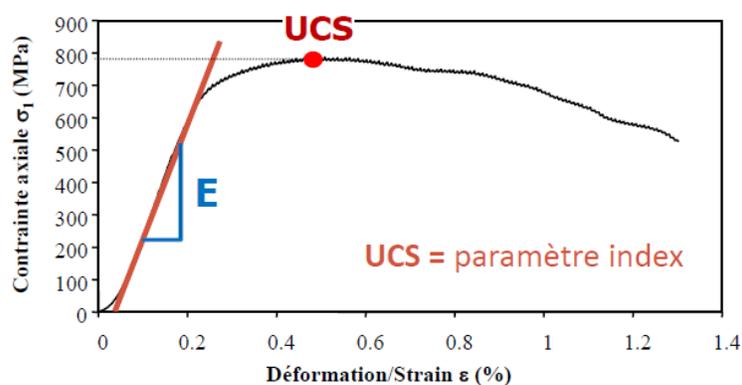


Figure 2-8 Courbe typique d'un essai de compression uniaxiale (Belem, 2022 ; Notes de cours)

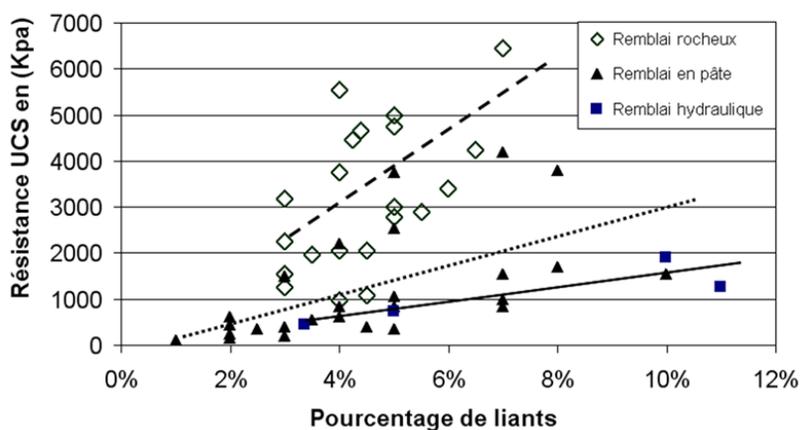


Figure 2-9 Comparaison de la résistance mécanique des trois types de remblai utilisés dans l'industrie minière (Gauthier, 2004)

2.3.2.2 Résistance à la compression triaxiale

Les essais à la compression triaxiale permettent de déterminer les paramètres intrinsèques du remblai à savoir la cohésion (c) et l'angle de frottement (ϕ) qui seront nécessaires lors du design du remblayage. Les essais s'effectuent en confinant l'échantillon avec différentes pressions de confinement (σ_3) dans une paroi rigide en appliquant dans un même temps une contrainte verticale (σ_1) jusqu'à la rupture (Figure 2-10). Des essais de compression triaxiale sur des remblais en pâte cimenté ont révélé que plus le pourcentage de liant est important, plus sa cohésion (c') sera élevée et plus l'angle de frottement interne (ϕ') sera faible (Belem et al., 2000a).

Selon les conditions de drainage imposées et les vitesses de chargement choisies, on trouve trois types d'essais triaxiaux (Mbonimpa, 2021; Notes de cours 2021) :

- Essai consolidé et drainé (*consolidated-drained*) CD : lors de l'essai, l'échantillon est drainé complètement pendant la consolidation sous l'effet de la contrainte de confinement σ_3 (dissipation complète de la pression interstitielle) puis la contrainte axiale σ_1 est appliquée lentement en laissant l'échantillon se drainer aussi pendant le cisaillement, de sorte que la pression interstitielle n'augmente pas, jusqu'à la rupture. Ce test permet de déterminer les paramètres effectifs de résistance au cisaillement tels que la cohésion drainée (c') et l'angle de frottement interne drainé (ϕ'). Ces paramètres seront nécessaires pour l'analyse des situations de remblai à long terme (analyse de stabilité à long terme où les chargements sont très lents).
- Essai consolidé et non drainé (*consolidated-undrained*) CU : au cours de cet essai, la consolidation est autorisée pendant la première phase qui suit la phase de cisaillement où le drainage n'est pas autorisé.
- Essai non consolidé et non drainé (*unconsolidated-undrained*) UU : durant cet essai, les tubes de drainage sont fermés. La contrainte de confinement σ_3 est appliqué suivi rapidement par la contrainte verticale σ_1 jusqu'à la rupture (le drainage n'est pas permis). Ce test permet de déterminer les paramètres totaux de résistance au cisaillement tels que la cohésion non drainée (c_u ou c_{tot}) et l'angle de frottement interne non drainé (ϕ_u ou ϕ_{tot}). Ces paramètres seront nécessaires pour l'analyse des situations de remblai à court terme (analyse de stabilité à court terme où les chargements sont rapides) et qui peuvent être obtenues à partir d'un essai CU.

Le drainage de l'eau favorise la diminution des pores vides et la porosité et donc augmente l'UCS. Ceci est dû au fait que la perte d'eau entraîne le tassement de la masse de remblai en pâte

(augmentation de la densité de tassement) et par conséquent, la réduction de la porosité totale et du taux de vide du matériau de remblai.

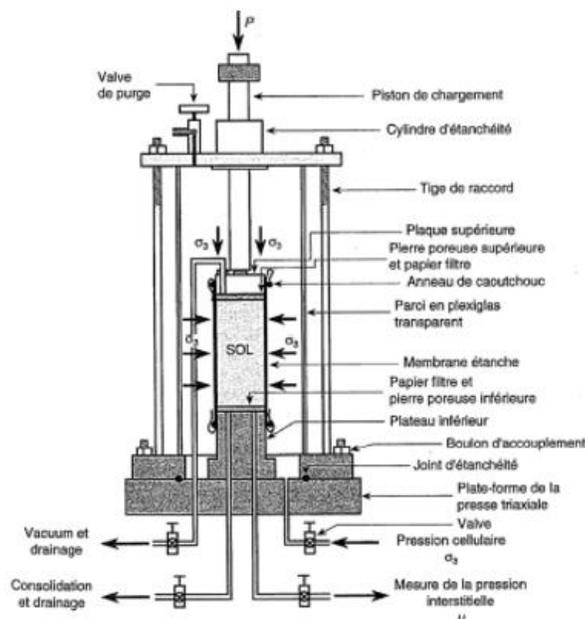


Figure 2-10 Appareil triaxial (Robitaille et Tremblay, 1997)

Les essais triaxiaux permettent de représenter la courbe de déviateur de contrainte ($\sigma_1 - \sigma_3$) en fonction de déformation axiale (Figure 2-11).

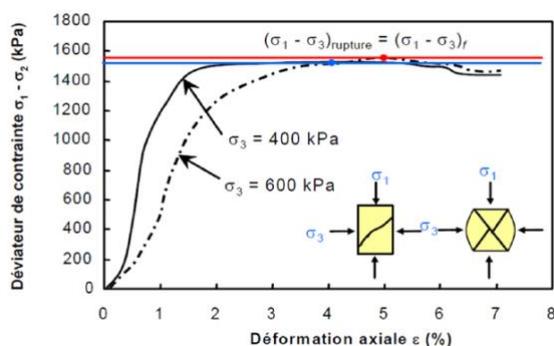


Figure 2-11 Courbe typique d'essais en compression triaxiale sur des remblais en pâte (Belem, 2022 ; Notes de cours)

2.3.2.3 Résistance au cisaillement

L'essai de cisaillement direct a pour but d'analyser la résistance au cisaillement (état critique) du remblai en pâte. Cette résistance est un paramètre clé de la conception: de la surcharge du remblai

(plancher de travail), de la stabilité de la masse de remblai (dans le cas d'une face exposée), de l'ouvrage de soutènement et des barricades de retenue de remblais. Divers critères ont été utilisés pour étudier le comportement à la rupture de ce dernier, le plus répandu c'est le critère de Mohr-Coulomb qui s'exprime selon l'équation (2-9) :

$$\tau = c' + \sigma'_n \tan \phi' \quad (2-9)$$

Avec τ : la résistance au cisaillement = contrainte de cisaillement à la rupture

c' : cohésion effective du RPC

ϕ' : angle de frottement interne effectif

σ'_n : contrainte normale effective

La Figure (2-12) représente la machine d'essai de cisaillement ainsi que l'enveloppe de rupture de Mohr-Coulomb dont il faudrait trois essais au minimum pour le tracer.

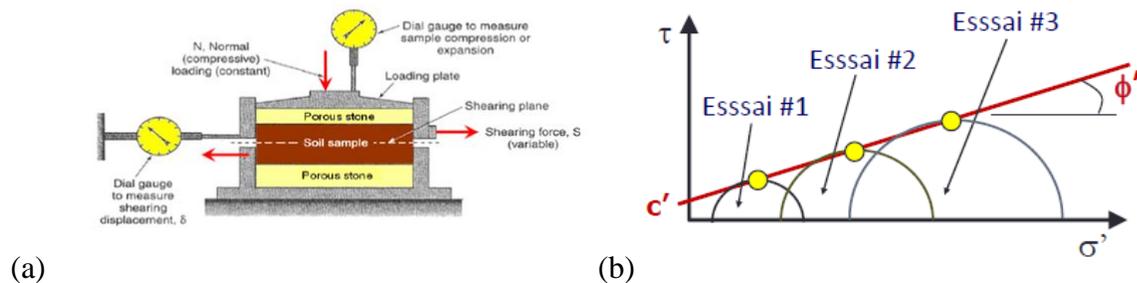


Figure 2-12 (a) Schéma d'une machine de cisaillement direct (McCarthy, 2010), (b) Enveloppe de rupture avec cohésion (Belem, 2022; Notes de cours)

2.3.3. Modèles analytiques de prédiction de l'UCS des remblais miniers

Depuis les années 80, plusieurs chercheurs tentent de développer des modèles semi-empiriques pour prédire la résistance à la compression uniaxiale des remblais, et accessoirement leurs propriétés intrinsèques (c' et ϕ').

a) Modèle de Mitchell et Wong (1982)

Mitchell (1989) a proposé un modèle semi-empirique de prédiction de la résistance à la compression uniaxiale (UCS) en kPa qui est donné par la relation suivante :

$$UCS = K_1 c^a (n^{-6} w^n + K_2) \quad (2.10)$$

Avec : n = la porosité (%), w = la teneur en eau (%), c = le pourcentage de liant (%), a = une constante déterminée expérimentalement qui varie entre 1,1 et 1,7 pour différents types de résidus, K_1 , K_2 et a sont des constantes.

b) Modèle de Swan (1985)

Swan (1985) a élaboré une relation empirique pour estimer l'UCS (en kPa) de remblais granulaires:

$$UCS = 0.283 \left(\frac{B_v}{d_{avg} a_p} \right)^{2.36} \quad (2.11)$$

Avec : B_v = pourcentage volumique du ciment dans le remblai (%), d_{avg} (cm) = distance moyenne des particules dans le mélange et a_p (cm²/g) = surface spécifique des agrégats pour un rapport E/C constant donné.

c) Modèle de Lamos et Clark (1989)

Lamos and Clark (1989) ont développé un modèle empirique statistique qui prédit la résistance à la compression (UCS) de différents types de remblai minier préparés avec différents types de liant. Ce modèle a été élaboré pour un temps de cure unique de 28 jours à une température de 30° et 100% d'humidité et à 72% solides:

$$UCS = 1 \text{ MPa} \left[p_1 + \left(p_2 \left(\frac{OPC}{E} + p_3 \frac{PFA}{E} + p_4 \frac{PBF}{E} \right) \right) \left(1 + p_5 \frac{CT}{NCS} + p_6 \frac{CW}{NCS} \right) + p_7 \frac{NCS}{E} \right] \quad (2.12)$$

Avec : $p_1 = 2,15$; $p_2 = 5,65$; $p_3 = 0,67$; $p_4 = 1,60$; $p_5 = 0,07$; $p_6 = 0,34$; $p_7 = 0,21$

OPC : ciment Portland ordinaire; *PFA* : OPC + cendres pulvérisées de carburant ou cendres volantes (ratio 1 :2); *PBF*: OPC + laitier de haut fourneau ou slag (ratio 1:1); *E* : eau ; *CT* : résidus classifiés ; *CW* : stériles broyés ; *NCS* : particules non cimentaires.

d) Modèle de Arioglu (1984)

Arioglu (1983) a proposé une relation empirique qui relie la résistance à la compression uniaxiale du remblai aux granulats cimenté (*cemented aggregate fill* – CAF) et le rapport eau/ciment (E/C) :

$$\sigma_c = UCS = A \left(\frac{E}{C} \right)^{-n} \quad (2.13)$$

Avec : A et n = constantes à déterminer expérimentalement.

Cet auteur a également élaboré une relation empirique entre la cohésion (c) et la résistance en compression uniaxiale ($\sigma_c = UCS$) qui ne suit pas (ignore l'existence) le critère classique et bien connu de Mohr-Coulomb :

$$c = A\sigma_c + B \quad (2.14)$$

e) **Modèle de Yu (1989)**

Yu (1989) a modifié le modèle d'Arioglu (1984) précédant pour établir une relation exponentielle (au lieu d'une loi puissance dans l'équation 4) entre la résistance en compression uniaxiale et la proportion massique du liant (c) :

$$UCS = e^{0.25 c} \quad (2.15)$$

Avec $2 \leq c \leq 10$ %.

f) **Modèle de Belem (2009)**

Mis à part les modèles présentés par les équations (2) et (3), tous les modèles précédents de prédiction sont purement empiriques et prennent pas en considération, ni le temps de cure (processus d'hydratation des liants), ni les propriétés physique, chimique et minéralogique des ingrédients principaux des remblais miniers. Il est donc permis d'affirmer que la prédiction de l'UCS des remblais en pâte cimentés est très complexe, car il faudrait prendre en considération toutes les propriétés chimiques, minéralogiques et physiques des ingrédients (résidus miniers, liant et l'eau). C'est dans cette optique que (Belem, 2009) a développé un modèle semi-analytique (ou semi-empirique) de prédiction de l'UCS des RPC, qui prend en considération :

- Le type de résidus miniers au travers de sa densité relative ($\rho_{s\text{-résidu}}$);
- Le type d'agent liant (α_B)
- La proportion massique de l'agent liant ($k.B_w\%$)
- La granulométrie des résidus au travers la proportion des fines (α_T)
- La qualité relative (chimie) de l'eau de mélange (α_w)

- Le temps de cure (t).

Le modèle de (Belem, 2009) qui s'appuie sur le modèle de pression partielle de vapeur (*vapor partial pressure model*) est donné par la relation suivante :

$$UCS (kPa) = G_{s-résidus} \left(\frac{1}{4} + kB_{w\%} \right) \times \exp \left[\alpha_B - \frac{\alpha_T}{t} - \alpha_w \ln(t) \right] \quad (2.16)$$

$$G_{s-résidus} = \frac{\rho_{s-résidus}}{\rho_{eau}} \quad (2.17)$$

Avec : $\rho_{s-résidus}$ = la masse volumique spécifique des grains de résidu (t/m^3 ou en g/cm^3); ρ_{eau} = la masse volumique de l'eau à 4°C (g/cm^3); k = facteur de pondération de la proportion de liant (kPa), α_B = facteur de pondération pour le type de liant; α_T = facteur de pondération de la granulométrie des résidus; α_w = facteur de pondération de la chimie de l'eau; t = temps de cure (en jour) et $B_{w\%}$ = pourcentage de liant. Les facteurs de pondération k , α_T et α_B sont déterminés empiriquement par les relations suivantes:

$$\alpha_T = 0.75380 \times (P_{20 \mu m}) - 10.308 \quad (2.17b)$$

$$H_a \approx 0.4248(Hm_b)^{0.9985} \quad (2.17c)$$

$$Hm_b \approx a + b(y_{SCM}) + c(y_{SCM})^2 + d(y_{SCM})^3 \quad (2.17d)$$

$$\alpha_B = a_1(H_a - b_1)^{c_1} \quad (2.17e)$$

$$k = a_2(H_a - b_2)^{c_2} \quad (2.17f)$$

Les constantes a , b , c , d , a_1 , a_2 , b_1 , b_2 , c_1 et c_2 sont données dans les Tableaux 2-4 et 2-5.

Tableau 2-4 Valeurs des constantes d'ajustement polynomiales à utiliser avec Éq. (2.17c) (Sahi, 2016 ; Belem and Benzaazoua, 2015)

Constante	GU/Slag	GU/FAC	GU/FAF
a	2.3573	2.3494	2.3159
b	-2.6020	-4.1585	-5.9567
c	1.4972	3.3457	6.3030
d	-0.4521	-1.2020	-2.6423

Tableau 2-5 Constantes pour le calcul des facteurs de pondération α_B et k (Belem, 2009)

Paramètre α_B	Fly ash F (FA-F)	Fly ash C (FA-C)	Scories (Slag)	Paramètre k	Fly ash F (FA-F)	Fly ash C (FA-C)	Scories (Slag)
a_1	3,524	4,517	4,517	a_2	1,417	1,418	1,625
b_1	-0,0035	-0,0036	0,0414	b_2	-0,0047	-0,0105	0,0218
c_1	0,0103	0,0162	0,0194	c_2	-0,0242	-0,0385	-0,0534

2.4. Généralités sur l'intelligence artificielle (IA)

2.4.1. Historique de l'IA

L'idée de l'intelligence artificielle (IA) est apparue depuis les années 50 par le mathématicien britannique Alan Turing qui proposa un test qui a été plus tard désigné sous le nom de « test de Turing » pour mesurer l'intelligence des machines et la comparer à celle des humains. Ce test consiste à faire communiquer en verbale une personne avec deux interlocuteurs : un autre humain et un ordinateur qu'il ne voit pas, puis après une conversation si la personne n'arrive pas à les distinguer alors on peut considérer que le logiciel de la machine a passé le test de Turing avec succès (Turing, 1950). En 1958, le psychologue Frank Rosenblatt inventa le premier programme d'apprentissage grâce à un réseau de neurones qu'il a appelé « Perceptron » (Rosenblatt, 1958), qui a ensuite été amélioré par Noam Chomsky qui développa des modèles mathématiques de langage pour les rendre compréhensibles aux machines (Pater, 2019). En 1956, le premier logiciel de l'IA « *Logic Theorist* » a été créé par Allen Newell et Herbert Simon pour imiter la capacité de résolution des problèmes d'un être humain (Newell and Simon, 1956). Plus tard, en 1966 au Massachusetts Institute of Technology (MIT), l'informaticien Joseph Weizenbaum a développé le programme informatique « ELIZA » qui permet de communiquer en langage naturel avec un ordinateur et qui remplace également les psychothérapeutes pendant les consultations thérapeutiques (Weizenbaum, 1966) ; ce programme a aussi passé avec succès le test de Turing (Newell and Simon, 1956). À partir de 1990, l'intelligence artificielle s'installe dans les laboratoires de recherche grâce au progrès de l'informatique et le début du Bigdata (données volumineuses) et jusqu'en 1997, le *Deep Learning* (apprentissage profond) est apparu grâce à des chercheurs comme Yann LeCun qui inventa des techniques de reconnaissance vocale et visuelle

d'objets (LeCun et al., 2015). Avec le progrès de la science de l'informatique, l'intelligence artificielle est intégrée de plus en plus jusqu'à nos jours dans différents domaines :

- Finance et banques : développement des systèmes experts pour l'évaluation des risques liés à l'octroi des crédits (Lotfi and Mesk, 2021).
- Médecine : utilisation de systèmes de diagnostic automatisés et de détection de différentes maladies. De nombreux systèmes intelligents ont même été utilisés lors de l'apparition de la pandémie de la COVID-19 pour lutter contre ce dernier (Lodé et al., 2020).
- Renseignement policier : prédiction des crimes à partir des données existantes (Ventos and Fantun, 2021).
- Logistique et transport : développement de voitures (Toque, 2019).
- Robotique : perception de l'environnement (visage et objets) (Droniou, 2015).
- L'industrie : développement de systèmes de maintenance prédictive pour la détection des problèmes dans les chaînes de production (Racoceanu, 2006).

2.4.2. Définition de l'IA

Depuis quelques années sont apparus les termes « intelligence artificielle » (IA), *Machine Learning* (ML) et *Deep Learning* (DL). Parfois ces termes sont souvent confondus alors qu'ils ont chacun une signification bien distincte même s'ils restent étroitement liés. En effet, il s'agit de différents niveaux de la même discipline (Figure 2-13).

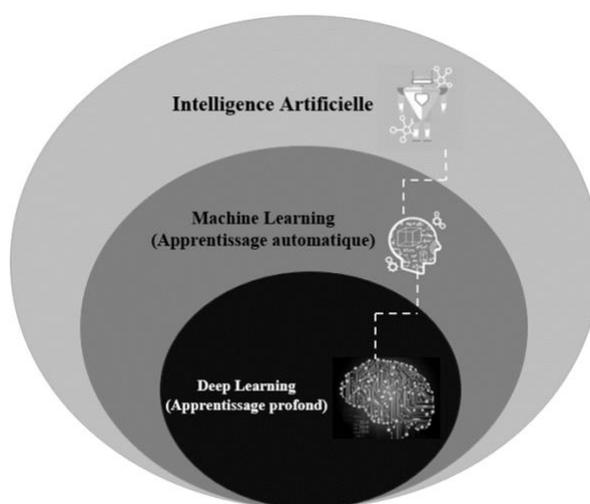


Figure 2-13 Les différents niveaux de l'intelligence artificielle

L'intelligence artificielle est le terme le plus large, et correspond à un processus évolutionniste qui permet aux machines d'imiter une forme d'intelligence humaine grâce à l'assemblage des théories mathématiques et des techniques informatiques.

L'intelligence c'est de savoir réagir rapidement à une situation complexe ou imprévue, de trouver la réponse satisfaisante plutôt que la réponse optimale, c'est de savoir également trouver ce qui est important dans une information, et tout cela en utilisant une stratégie caractéristique du vivant. L'approche numérique ou connexionniste tente d'imiter comment l'humain apprend, par essais et erreurs, à partir de ses expériences ; d'où le terme « artificielle » (Figure 2-14).



Figure 2-14 Notion de l'intelligence artificielle

2.4.2.1. Apprentissage automatique (*Machine Learning*)

L'apprentissage automatique ou *Machine Learning* (ML) est une discipline de l'intelligence artificielle. Elle s'appuie sur le fait qu'un algorithme apprend par lui-même sans être explicitement programmé à partir de séries de données d'historiques appelées les données d'apprentissage à l'aide des méthodes statistiques qui permettent de faire des analyses et des prédictions (Laloë, 2009).

La mise en œuvre de cette technologie nécessite l'existence de données structurées qu'un algorithme en *Machine Learning* (ML) utilise pour développer un modèle ; par exemple, une fonction simple de type $f(x) = ax + b$ (Figure 2-15). Le but en *Machine Learning*, c'est de trouver les paramètres a et b qui donnent le meilleur modèle possible qui s'ajuste le mieux aux données. C'est pour cela qu'il existe des algorithmes d'optimisation comme l'algorithme de descente de gradient, l'algorithme des arbres de classification et de régression (Classification and Regression Tree-CART) pour les arbres de décision et la marge maximum pour le *Support Vector Machines* ou SVM) qui vont tester les différentes valeurs de a et b afin d'obtenir la combinaison qui minimise la distance entre le modèle et les points de données (Jordan and Mitchell, 2015).

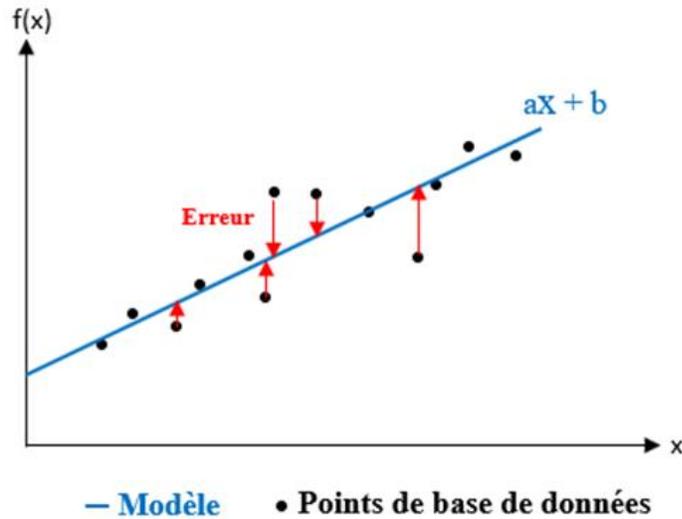


Figure 2-15 Modèle simplifié en *Machine Learning*

La méthodologie à suivre pour implanter un modèle en *Machine Learning* est illustrée dans la Figure (2-16), et elle consiste à collecter les données en premier lieu, afin de construire une base de données puis de les préparer, dont un filtrage et des traitements sont nécessaires avant de faire apprendre et tester des modèles sur ces données.

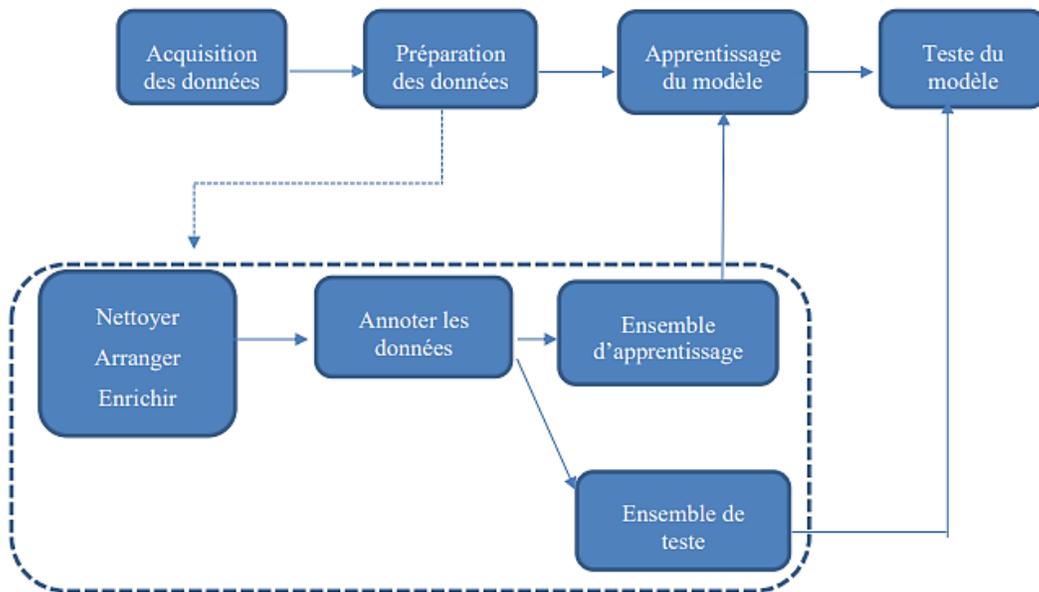


Figure 2-16 Méthodologie d'implantation des algorithmes en *Machine Learning*

Il existe principalement trois types d'algorithmes pour l'apprentissage automatique à partir de données et selon les problèmes à résoudre et les données disponibles. La Figure 2-17 résume ces types.

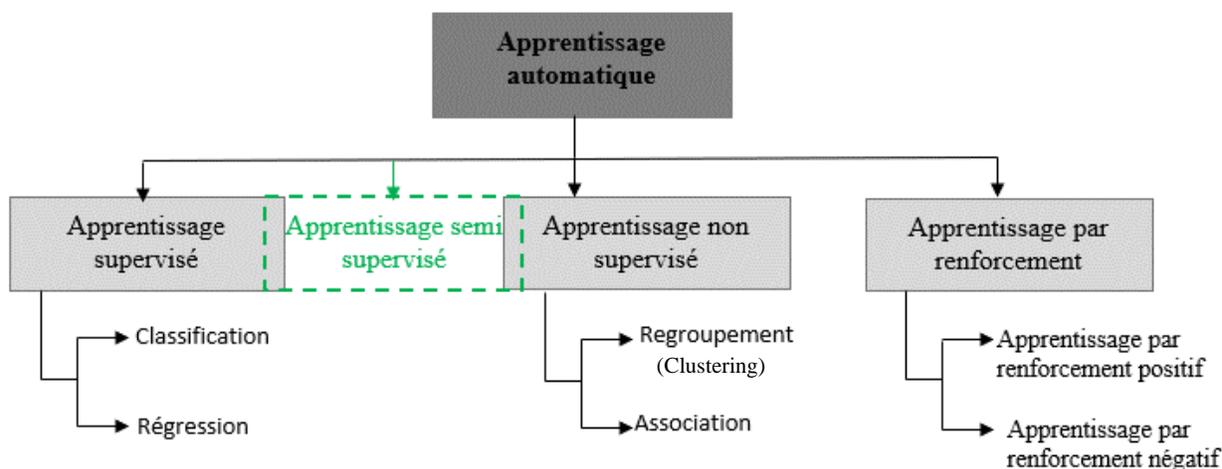


Figure 2-17 Différents types d'apprentissage automatique (ML)

a) Apprentissage supervisé : montrer à un algorithme ce qu'il doit faire

L'algorithme est entraîné sur une base de données qui contient des cas concrets, traités et validés. On peut désigner ces données par $\{X_i\}_{1 \leq i \leq N}$ qui représente les données d'entrées (*features*), tandis que la sortie est Y (*target*). Le but de cette opération est de définir la fonction f qui relie les données d'entrée X_i et la donnée de sortie Y (variable à prédire) tel que $Y = f(X_1, X_2, \dots, X_n)$. Une fois que l'algorithme a appris, il sera capable de prédire les variables de sortie (Y) lorsque des nouvelles données $\{X_i\}_{1 \leq i \leq N}$ seront introduites (Laloë, 2009).

Dans ce type d'apprentissage, on peut résoudre des problèmes de **régression**, c'est-à-dire quand la variable à prédire est une variable continue (quantitative) et on peut également résoudre des problèmes de **classification** lorsque la variable à prédire est une variable discrète (qualitative).

Les algorithmes d'apprentissage supervisé sont : *régression linéaire*, *k-Nearest Neighbour (kNN)*, *régression logistique*, *Support Vector Machine (SVM)*, *Naive Bayes*, *Neural Network (NN)*, *Random Forest (RF)*, *Adaboost*, *Gradient Boosting* et aussi *les réseaux de neurones*.

b) Apprentissage non supervisé : laisser la machine apprendre toute seule

C'est une méthode d'apprentissage dans laquelle, au lieu de montrer à l'algorithme des données d'entrée et de sortie sur lesquelles il doit apprendre, on lui fournit uniquement des données d'entrée

et on lui demande d'analyser la structure de ces dernières pour apprendre lui-même à réaliser certaines tâches. Par exemple, l'algorithme peut apprendre à classer des données en les regroupant par leur ressemblance. Cette tâche s'appelle la **classification non supervisée** ou *Clustering*. Avec cette méthode, on peut également détecter des anomalies, dont la machine examine la structure des données et parvient à trouver les caractéristiques d'un échantillon qui sont très éloignées de celle des autres échantillons et cela permet de développer des systèmes de sécurité, de détecter des défaillances techniques et même en recherche médicale au niveau du classement de nouvelles maladies et de nouvelles bactéries. Une autre tâche que cette méthode peut faire est la « Réduction de la dimensionnalité ». Dans ce cas, la machine analyse la structure des données et simplifie ses structures tout en conservant les principales informations (Jordan and Mitchell, 2015).

Les algorithmes les plus utilisés en apprentissage non supervisé sont : *k-mean Clustering*, *Principal Component Analysis (PCA)*, *Anomaly Detection Systems (ADS)*, *Generative Adversarial Network (GAN)*, *Auto-encoder Neural Networks(A-eNN)* et *Manifold Learning*.

On utilise l'apprentissage non supervisé dans les cas où les données sont non étiquetées (mal comprises, voire inconnues). Cependant, pour l'apprentissage supervisé, les données doivent être étiquetées.

c) Apprentissage semi-supervisé

L'apprentissage semi-supervisé est l'association de l'apprentissage automatique supervisé et non supervisé. Même s'il utilise des ensembles de données étiquetées et non étiquetées pour former des modèles et prédire les résultats, il comprend principalement des ensembles de données non étiquetées (Jordan and Mitchell, 2015).

d) Apprentissage par renforcement : laisser la machine générer sa propre expérience

Ce type d'apprentissage se fait par interaction avec l'environnement, mais sans supervision. Il permet à un agent (algorithme) de faire l'apprentissage d'un comportement qui n'a jamais été précédemment défini. L'agent découvrira l'environnement et les conséquences de ses différents actes en interagissant. Il apprend à partir de sa propre expérience et cela sans avoir aucune connaissance préalable des objectifs ou des conséquences de ses actions. Ce type d'apprentissage est utilisé pour développer des voitures autonomes, des drones, des robots et dans les jeux vidéo (Jordan and Mitchell, 2015).

Les algorithmes utiles en apprentissage par renforcement sont la recherche par la méthode Monte-Carlo, SARSA (*State–action–reward–state–action*), *Temporal Difference Learning (TDL)* et le *Q-Learning*.

2.4.2.2. Apprentissage profond (*Deep Learning*)

Il existe un type particulier d'algorithmes en *Machine Learning* qui sont les algorithmes de *Deep Learning* (apprentissage profond) utilisant les réseaux de neurones artificiels qui sont efficaces dans tous les domaines où les autres algorithmes de l'intelligence artificielle ont échoué. Les réseaux de neurones artificiels sont inspirés des réseaux de neurones biologiques des humains (Figure 2-18-a). Ils imitent des tâches, dont le principe de fonctionnement d'un cerveau humain, et il n'a pas besoin de données structurées. Cette approche est notamment adaptée aux tâches complexes (reconnaissance faciale et vocale, véhicules autonomes et moteur de recherche, etc.), quand tous les aspects des objets à traiter ne sont pas susceptibles d'être catégorisés à l'avance (Chollet, 2020). Le programme d'apprentissage profond définit lui-même les caractéristiques discriminantes. À chaque couche, il tente de trouver un nouveau critère spécifique à l'objet afin de classifier l'objet à la fin du processus (Figure 2-18-b).

Il existe différents types de réseaux de neurones pour l'apprentissage profond qui sont : le réseau de neurones *feedforward*, le réseau de neurones à fonction de base radiale, le perceptron multicouche, le réseau neuronal convolutif (*convolutional neural network – CNN*), le réseau neuronal récurrent (*recurrent neural network – RNN*) et le réseau neuronal modulaire (*modular neural network – MNN*).

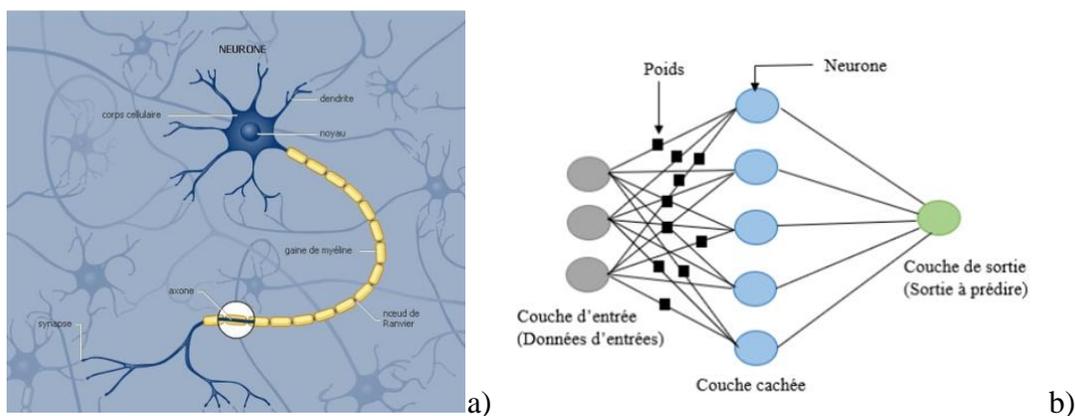


Figure 2-18 Réseau de neurones : a) biologiques, b) artificiels (Djeriri, 2017)

Le Tableau 2-6 présente une synthèse des principales différences entre l'apprentissage automatique (*Machine Learning*) et l'apprentissage profond (*Deep Learning*).

Tableau 2-6 Synthèse des différences entre *Machine Learning* et *Deep Learning*

	<i>Machine Learning</i>	<i>Deep Learning</i>
Organisation des données	Données structurées (étiquetées)	Données non structurées (non étiquetées)
Base de données	Contrôlable	> 1 million de données
Entraînement	Entraînement par l'humain nécessaire	Système d'apprentissage autonome
Algorithme	Algorithme modifiable	Algorithmes de réseau neuronal
Champ d'application	Actions simples de routine	Tâches complexes
Intervention humaine	Nécessaire	Plus au moins

Le choix de la méthode de travail avec le *Machine Learning* ou le *Deep Learning* dépend essentiellement de la complexité d'application visée, de la quantité de données disponibles et de la disponibilité d'un GPU (*graphics processing unit* ou processeur graphique) pour le traitement rapide des données.

2.5. Intelligence artificielle dans l'industrie minière

2.5.1. Détection de défaillances dans les mines

Grâce aux progrès de technologie de l'information, l'apprentissage automatique est devenu une technologie indispensable dans les industries. En effet, ces technologies (IA) pourraient améliorer considérablement la productivité et l'efficacité des opérations minières qui sont des activités reconnues comme comportant parfois certains risques. On peut dénombrer les potentiels facteurs à risque suivants : un environnement confiné (espace restreint), un mauvais éclairage, une accumulation de déchets dangereux et parfois de gaz toxiques, des particules de poussière provenant de métaux et de substances toxiques, des matières radioactives, de la mauvaise ventilation/alimentation en air, l'utilisation d'explosifs et des épontes instables. Toutefois, avec l'existence de l'IA et des technologies autonomes, il est possible de réduire au minimum l'exposition des travailleurs aux opérations souterraines et des surfaces dangereuses. Les machines

peuvent surveiller l'atmosphère de manière autonome, envoyer des signaux et des avertissements, localiser les zones problématiques et travailler en continu, même dans des situations dangereuses (Hyder et al., 2019).

Voilà pourquoi plusieurs recherches ont été réalisées dans ce contexte tel que la classification d'événements microsismiques (Duan et al., 2021) qui est basée sur le traitement de 8 000 signaux sismiques enregistrés par des géophones ainsi que l'implantation de plusieurs modèles d'apprentissage automatique tels que le RF (*Random Forest*), SVM (*Support Vector Machine*), DCNN (*Deep Convolutional Neural Network*) et le ResNN (*Residual Neural Network*). Des améliorations étape par étape du modèle fiable DCNN et d'une base de données ont été étudiées. Les résultats montrent que les événements sismiques associés aux fractures rocheuses ont été identifiés et localisés à l'intérieur de la digue et sur le toit immédiat.

Une autre étude a été réalisée sur l'évaluation du risque d'éclatement des roches (*rockburst*) dont onze paramètres ont été pris en compte pour la création de l'ensemble des données d'entrée, ensuite quatre algorithmes d'apprentissage automatique ont été construits : DT (*Decision Tree*), RF (*Random Forest*), MLCP (*Mixed Linear Complementarity Problem*) et XGBoost (*Extreme Gradient Boost*) puis entraînés sur l'ensemble des données afin d'évaluer le risque d'éclatement des roches dans les excavations souterraines. Les modèles les plus fiables au niveau d'identification de l'anomalie sont DT et MLCP (Wojtecki et al., 2022).

Les incendies de galeries dans les mines ont fait également l'objet d'études approfondies, car ils constituent une menace considérable pour la sécurité des travailleurs miniers (Hong et al., 2022). Ainsi, l'utilisation de modèles d'apprentissage automatique avec des calculs et simulations numériques permettent de prédire le mouvement des fumées des incendies dans les galeries minières dont quatre algorithmes de ML : *i*) le modèle des forêts aléatoires (RF), *ii*) la machine à vecteurs de support (SVM), *iii*) le modèle de réseaux de neurones artificiels (ANN) et *iv*) le modèle des arbres de classification et de régression (CART) ont été entraînés sur une base de données de 1000 cas d'incendies et qui contient des paramètres de ventilation, thermiques et géométriques (Hong et al., 2022).

2.5.2. Détection de défaillances dans les mines souterraines

a) Coups de terrains (*Rockburst*)

L'éclatement des roches est un phénomène dynamique dangereux qui se produit dans les excavations souterraines (coups de terrains). Il est associé à une libération violente de l'énergie, à une déformation inélastique des roches et à une éjection des roches dans les excavations (Wojtecki et al., 2022).

Lorsqu'une rupture fragile se produit dans les roches environnantes, il y a d'abord un bruit court et aigu, suivi de la libération d'un mince éclat d'une zone de roche. Si l'épaisseur de l'éclat de roche est faible, l'éclatement peut se transformer en un écaillage superficiel sans éclatement prononcé; ce qui implique que l'énergie libérée n'est pas suffisante pour une action dynamique. Dans ce cas, la surface est rugueuse et généralement parallèle au front d'excavation. En revanche, si l'épaisseur de la roche qui se brise est importante, la libération de contraintes est plus significative et l'éboulement est plus dynamique et peut se développer à l'intérieur de la roche et un écaillage dans ce cas est très important (Jiang et al., 2010).

La Figure 2-19 montre quelques exemples du phénomène de *Rockburst*. La Figure 2-19a montre un écaillage de surface, la Figure 2-19b illustre une excavation profonde due à l'éclatement de la roche, une rupture schisteuse (sous forme de feuillets rocheux) dans l'excavation est présentée dans la Figure 2-19c et une forme parabolique de la roche de desquamation est illustrée dans la Figure 2-19d.



Figure 2-19 Exemples d'éclatement des roches dans les galeries de mines souterraines (Jiang et al., 2010)

Le mouvement de la masse rocheuse dans les mines souterraines est considéré comme l'un des phénomènes les plus dangereux qui peuvent provoquer l'effondrement des structures (Ping-lu et al., 2009) parce qu'un déplacement excessif conduit à la rupture du massif. Il pourrait être causé par l'excavation des galeries et les opérations minières souterraines comme le dynamitage.

Li et al. (2022) ont prédit le déplacement des roches dans les galeries et dans les mines souterraines à l'aide des modèles d'apprentissage automatique tels que le modèle de machine à vecteurs de support (SVM) avec l'intégration de deux nouveaux modèles de calcul logiciel, à savoir l'algorithme d'optimisation de Harris Hawks (HHOA) (c'est-à-dire HHOA-SVM) et l'algorithme d'optimisation de Grasshopper (GOA) (c.-à-d., GOA-SVM), ainsi que les réseaux de neurones artificiels (ANN).

b) Incendies dans les galeries

Les incendies dans les galeries des mines souterraines comptent parmi les catastrophes qui peuvent être causées par l'augmentation imprévue de température de certains gaz au toit, un problème au niveau du système de ventilation ou par des erreurs humaines.

Cependant, comme risque important pour les infrastructures, les incendies dans les tunnels causent chaque année de nombreux accidents. La Figure 2-20 montre quelques accidents graves récents dus à des incendies dans des tunnels. Deux camions sont entrés en collision en 2001 dans le tunnel routier de Gottard en Suisse, provoquant un incendie dans le tunnel (Figure 2-20a). En 2008, un incendie s'est produit sur un poids lourd dans le tunnel sous la Manche, côté France. Le feu s'est rapidement propagé du camion en feu aux 6 voitures suivantes (Figure 2-20b). En 2014, un camion de charbon est entré en collision avec un camion-citerne de méthanol à l'intérieur du tunnel de Yanhou en Chine, la flamme de méthanol liquide a provoqué une propagation rapide du feu et une série d'explosions, causant plus de 30 décès (Figure 2-20c). En 2015, un camion-citerne de pétrole a frappé le mur à l'intérieur du tunnel de Skatestraum en Norvège, faisant exploser environ 16 500 litres d'essence, et le feu s'est rapidement diffusé sur 500 mètres. Bien qu'il n'y ait eu aucun blessé grave, la paroi du tunnel a été gravement endommagée (Figure 2-20d). En 2019, un incendie s'est produit dans une seule voiture de taille moyenne dans le tunnel de Rannersdorf en Austria, en raison de défauts du véhicule (Figure 2-20e). En 2020, un accident avec incendie s'est produit dans le tunnel de Samae 2 en Corée du Sud, où des dizaines de chars et de camions sont entrés en collision, tuant quatre personnes et blessant plus de 40 autres (Figure 2.20f) (Zhang et al., 2021).

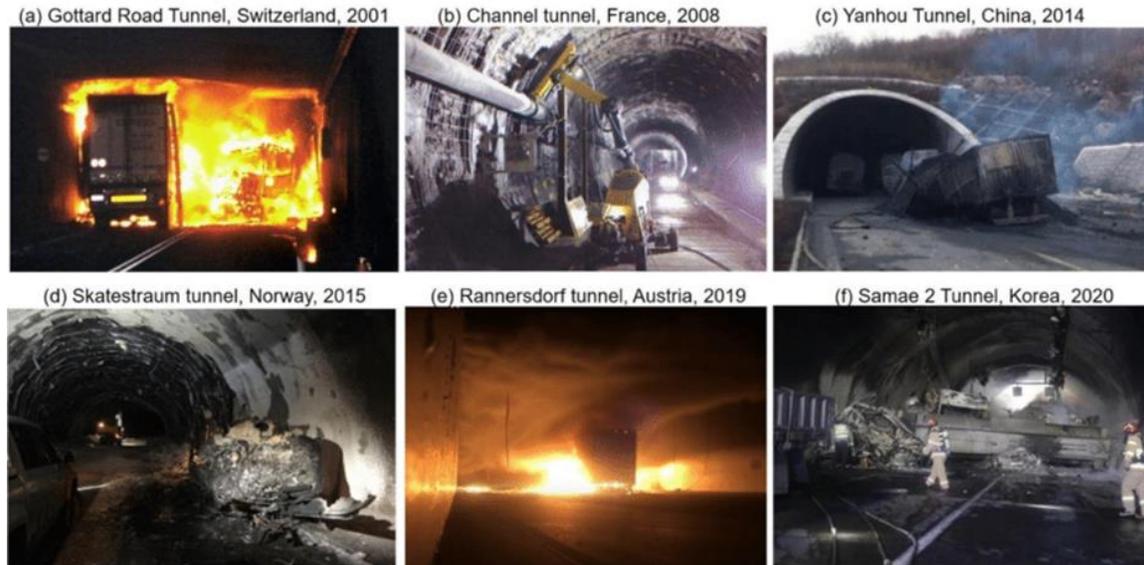


Figure 2-20 Exemples d'incendies dans des tunnels et dans des galeries de mines souterraines (Zhang et al., 2021)

2.5.3. Prédiction de la résistance à la compression uniaxiale de RPC par l'IA

Plus récemment, des chercheurs ont commencé à développer des modèles de Machine Learning pour prédire l'UCS des RPC. Principalement, Qi et al. (2018b) ont développé un réseau de neurones artificiels combiné avec un algorithme d'optimisation « *particle swarm optimization* - PSO » pour prédire la résistance à la compression uniaxiale de RPC. Un total de 396 d'essais a été fait pour construire la base de données qui ne contient que le type de résidus, le ratio ciment-résidus, le pourcentage solide et le temps de cure (3, 7, 28 jours) comme données d'entrées pour le ANN. Le coefficient de prédiction obtenu est de 0.979.

Yu et al. (2021), ont utilisé également comme méthode de prédiction, les réseaux de neurones artificiels (ANN), le modèle « *Support Vector Machine* - SVM » et un algorithme d'optimisation « *Salp Swarm Algorithm* - SSA » pour prédire l'UCS des RPC renforcé par des fibres polypropylène. La base de données utilisée pour l'apprentissage des modèles contient 720 essais d'UCS ; le ratio ciment-résidus, pourcentage de solide, temps de cure, pourcentage de fibre et longueur de fibre ont été utilisés comme données d'entrée. Le meilleur modèle de prédiction « Réseau de neurones artificiels combiné avec l'algorithme d'optimisation : SSA-ELM » a donné un coefficient de détermination sur les données de test de 0.94 et une racine de l'erreur quadratique moyenne (RMSE) égale à 0.18.

Lu et al. (2019) ont combiné un modèle d'apprentissage automatique « *Gradient Boosting Regression* » avec un algorithme d'optimisation PSO pour prédire l'UCS. Ils ont utilisé 126 essais d'UCS de RPC fait avec deux types de résidus et les données d'entrées qui ont été sélectionnées sont le ratio ciment-résidus (0.083 à 0.25), pourcentage de solide (66% à 78%), temps de cure (3, 7, 14 et 28 jours). Le score de prédiction obtenu par ce modèle est de 0.9837.

Qi et al. (2018a) ont utilisé une base de données un peu plus large de 1077 essais d'UCS et 231 essais de résistance à la traction uniaxiale (UTS) pour prédire les propriétés des RPC tels que l'UCS, l'UTS, le module d'élasticité et le module de Young. Ils ont utilisé trois modèles d'apprentissage automatique pour la prédiction (*Decision Tree* - DT, *Gradient Boosting Machine* - GBM et *Random Forest* - RF) et l'algorithme génétique pour l'optimisation des hyperparamètres. Les résultats montrent que le modèle GBM est le plus performant et donne un coefficient de corrélation de 0.963.

Comme le remblai est un matériau sensible à plusieurs facteurs tels que le type de liant et sa proportion, le type d'eau de mélange, la teneur en sulfure, les propriétés physico-chimique et minéralogique des résidus, toutes les études mentionnées ci-dessus n'ont pas pris en compte de ces facteurs dans la base de données pour l'apprentissage des modèles. Les industries minières auront besoin de connaître l'UCS à long terme (90 à 360 jours) de remblai pour satisfaire aux exigences techniques de l'exploitation, ce qui est n'été pas considéré dans ces travaux. Les performances de modèles d'apprentissage dépendent fortement de la quantité des données qu'ils reçoivent (plus qu'il y aura des données, sera meilleur ses performances). La majorité des travaux de recherches de prédiction de l'UCS de RPC ont utilisé des petites bases de données (inférieurs à 2000 essais de compression). Alors que ,les adjuvants chimiques peuvent améliorer l'UCS des RPC, et que le liant composé GU-Slag développe des résistances meilleures que le ciment GU seul (Sahi, 2016), la plupart des travaux de recherches ont utilisé un seul type de liant qui est le ciment portland, ce qui montre un manque de diversité au niveau de données d'entrées. Aussi un seul type d'eau a été utilisé (eau de robinet) pour formuler des recettes de mélanges.

C'est pour cette raison, que la présente étude vise à remédier aux limitations citées dans la littérature par l'implantation des algorithmes avancés d'apprentissage automatique tels que le *Random Forest* (RF), le *Gradient Boosting Regressor* (GBR) et le *Extreme Gradient Boosting Regressor* (XGBR) et un réseau de neurones profonds (DNN) pour prédire l'UCS de RPC sur la

base d'un vaste ensemble de données contenant 10 050 tests d'UCS en tenant compte des propriétés physiques, minéralogiques et chimiques des résidus ainsi que la chimie des eaux de mélanges. Des informations bien détaillées des différents mélanges de RPC seront décrites dans la base de données à savoir le type de liant, sa proportion, le pourcentage de solide, l'affaissement de la pâte de remblai, et le temps de cure.

2.6. Récapitulatif

Ce chapitre faisait la synthèse bibliographique sur les travaux antérieurs portant sur les différents types de remblais miniers ainsi que de l'utilisation des approches de l'intelligence artificielle dans l'industrie minière.

La première partie a décrit les différents types de remblais (remblais hydrauliques, remblais rocheux et remblais en pâte cimentés).

Ensuite on a mentionné une description plus détaillée du RPC et plus précisément ses caractéristiques mécaniques ainsi que les caractéristiques de ses ingrédients. Des modèles analytiques de prédiction de l'UCS de RPC ont été également présentés.

La deuxième partie a été consacrée pour un aperçu sur l'intelligence artificielle (apprentissage automatique et apprentissage profond), et l'intégration de ce concept dans l'industrie minière ainsi que pour la prédiction des propriétés des matériaux.

Le chapitre suivant décrira les matériels utilisés et les méthodes qui ont été suivis pour mener ce projet.

CHAPITRE 3 MATÉRIELS ET MÉTHODES

3.1 Introduction

Les différents matériaux utilisés (résidus, liant hydraulique et eau de mélange) dans ce projet seront présentés dans ce chapitre ainsi que les protocoles expérimentaux à savoir les méthodes de caractérisations physiques des résidus, le calcul des mélanges de RPC, la préparation des éprouvettes ainsi que la caractérisation de consistance de la pâte finale et la caractérisation de propriété mécanique de RPC. Les théories des modèles d'apprentissage automatique et des modèles d'apprentissage profond seront également bien détaillées à la fin de ce chapitre. Les différents résultats seront présentés dans le chapitre suivant (chapitre 4).

3.2 Matériels

Afin de bien maîtriser le comportement mécanique du RPC, il est primordial de savoir les différentes caractéristiques de chaque composant de remblai. Dans ce projet, des caractérisations physiques de différents résidus ont été faites au sein de laboratoire URSTM à l'UQAT. D'autres caractérisations chimiques et minéralogiques des ingrédients fournis par les différentes mines et d'anciens travaux de recherche (à l'URSTM aussi) seront pris en compte dans la base de données qui va servir à développer des algorithmes de Machine Learning et des réseaux de neurones artificiels pour la prédiction de l'UCS.

3.2.1 Résidus miniers

Cinq types de résidus fournis par différentes compagnies minières ont été utilisés dans cette étude: Mines Agnico Eagle (Divisions LaRonde et Goldex et mine Canadien Malartic), IAMGOLD Corp. (mine Westwood) et Mines Hecla Québec (mine Casa Berardi). Ces différentes mines sont situées dans l'ouest du Québec (région de l'Abitibi-Témiscamingue) au Canada. Ces résidus ont été livrés dans de grands barils (200 litres). Leurs préparations consistent en premier lieu à éliminer l'eau surnageant puis à les homogénéiser soigneusement pour éviter la ségrégation des particules (Figure 3-1) et à la fin à les répartir dans des chaudières de 20 litres. Des échantillons ont été prélevés à partir de ces résidus homogénéisés, puis ont été séchés afin de déterminer leurs teneurs en eau massique w (%). Après le séchage, ces échantillons ont été agglomérés et homogénéisés encore

une fois par la méthode des quatre points (Figure 3-2) pour déterminer leurs densités relatives des grains solides (D_R) et leurs distributions granulométriques.



Figure 3-1 Homogénéisation des résidus : a) résidu non homogénéisé; b) résidus en cours d'homogénéisation; c) résidu bien homogénéisé



Figure 3-2 Préparation des résidus pour la caractérisation physique a) agglomération des résidus; b) homogénéisation par la méthode de quatre points

3.2.2 Liants hydrauliques

Deux types de liant hydraulique très répandus dans les mines pour la formulation de RPC ont été utilisés pour la formulation de RPC :

- Le ciment Portland à usage général (GU) seul
- Le liant GU/Slag qui est composé de ciment Portland (GU) et du laitier de hauts fourneaux (Slag) à différentes proportions : 10GU/90Slag, 20GU/80Slag et 30GU/70Slag.

Deux autres types de liant ont été considérés dans la base de données :

- Le liant GU/FA-C composé de ciment Portland (GU) et les cendres volantes de types C
- Le liant GU/FA-F composé de ciment Portland (GU) et les cendres volantes de types F

Vu que le liant GU/Slag est connu par sa protection contre l'attaque sulfatique et par son bon développement de résistance, la majorité des formulations ont été faites avec ce type de liant.

Sahi (2016) a caractérisé ces différents agents liants par la spectrométrie à plasma à couplage inductif (ICP-AES). Les Tableaux 3-1 et 3-2 ci-dessous représentent respectivement les compositions chimiques et les caractéristiques physiques de ces agents liants et des ajouts minéraux.

Tableau 3-1 Compositions chimiques des agents liants et des ajouts minéraux

Type de ciment	SiO ₂ (%)	Al ₂ O ₃ (%)	Fe ₂ O ₃ (%)	CaO (%)	MgO (%)	Na ₂ O (%)	K ₂ O (%)	TiO ₂ (%)	P ₂ O ₅ (%)	MnO (%)	Cr ₂ O ₃ (%)	V ₂ O ₅ (%)
GU	19,3	4,99	2,97	64,3	2,1	0,27	0,5	0,27	0,26	0,12	0,01	0,03
Slag	35,6	10,5	0,65	37,5	11,9	0,46	0,51	0,98	0,93	0,5	<0,01	0,01
FAC	37,2	18,4	5,52	20,8	4,9	4,37	0,69	1,29	<0,01	0,02	0,02	0,05
FAF	45,3	22,5	19,2	4,02	0,97	0,6	1,66	1,13	0,13	0,03	0,03	0,05

Tableau 3-2 Caractéristiques physiques des agents liants et des ajouts minéraux

	GU	Slag	FAC	FAF
SS _m -BET (cm ² /g)	11000	27500	22400	9300
ρ _s (g/cm ³)	3,15	2,94	2,68	2,34
d _{av} (cm)	0,001411	0,000725	0,000888	0,002466

3.2.3 Eau de mélange

Deux types d'eaux ont été utilisées dans cette étude pour la préparation de différents mélanges de RPC à savoir l'eau de robinet et l'eau de procédé de la mine LaRonde.

D'autres eaux ont été considérées également dans la base de données telles que les eaux sulfatées avec des teneurs de 2500 mg/l et de 5000 mg/l qui ont été synthétisées au laboratoire par Sahi (2016) par l'ajout du sulfate de sodium (Na_2SO_4) à l'eau distillée. Les eaux de procédé des mines LZ5, Goldex, Westwood ont été également considérées.

L'utilisation de différents types d'eau dans les mélanges de RPC a pour but d'évaluer l'effet de chimie de l'eau sur l'UCS de remblai.

3.3 Démarche méthodologique

La méthodologie à suivre dans ce projet est divisée en deux parties : la première partie est dédiée aux travaux au laboratoire. En effet, la première étape consiste à caractériser les différents résidus miniers puis la deuxième étape c'est la préparation de différents mélanges de remblai. Ces mélanges ont été faits avec différents pourcentages solides (de 70% à 77%) de façon à obtenir différentes valeurs d'affaissement (de 5,75 po à 10 po). Environ 324 éprouvettes de RPC ont été fabriquées dans cette étude expérimentale au sein du laboratoire URSTM et entreposées dans une chambre humide. La troisième étape de la première phase c'est le cassage des éprouvettes par des essais de compression uniaxiale à chaque temps de cure (14, 28, 56 et 90 jours), afin de déterminer l'UCS. Tous les résultats obtenus servent à développer plus tard des modèles de Machine Learning et d'un réseau de neurones artificiels.

Quant à la deuxième phase, elle porte sur le développement et la programmation des algorithmes d'apprentissage automatique et d'apprentissage profond. La première étape primordiale, c'est la collecte des données : résultats de laboratoire (324 éprouvettes) et des données provenant des mines (9 726 éprouvettes). La deuxième étape c'est le traitement des données à savoir la gestion des données manquantes dans les bases de données des mines, l'analyse de corrélation entre eux, la normalisation de toutes les données pour qu'elles soient dans la même échelle afin de faciliter l'apprentissage des modèles et d'annoter les données catégorielles si nécessaire. Une fois que la base de données est bien traitée, elle sera divisée en deux parties : 80% des données seront consacrées pour l'apprentissage des modèles et 20% pour les tester. L'implantation des modèles, l'optimisation de leurs hyperparamètres suivie par une validation croisée ainsi que leurs évaluations et leurs validations à l'échelle de laboratoire seront faites ensuite, afin de sélectionner celui qui est performant pour arriver finalement au déploiement de celui-là par la création d'une application web. La Figure 3-3 illustre la méthodologie adoptée de ce projet.

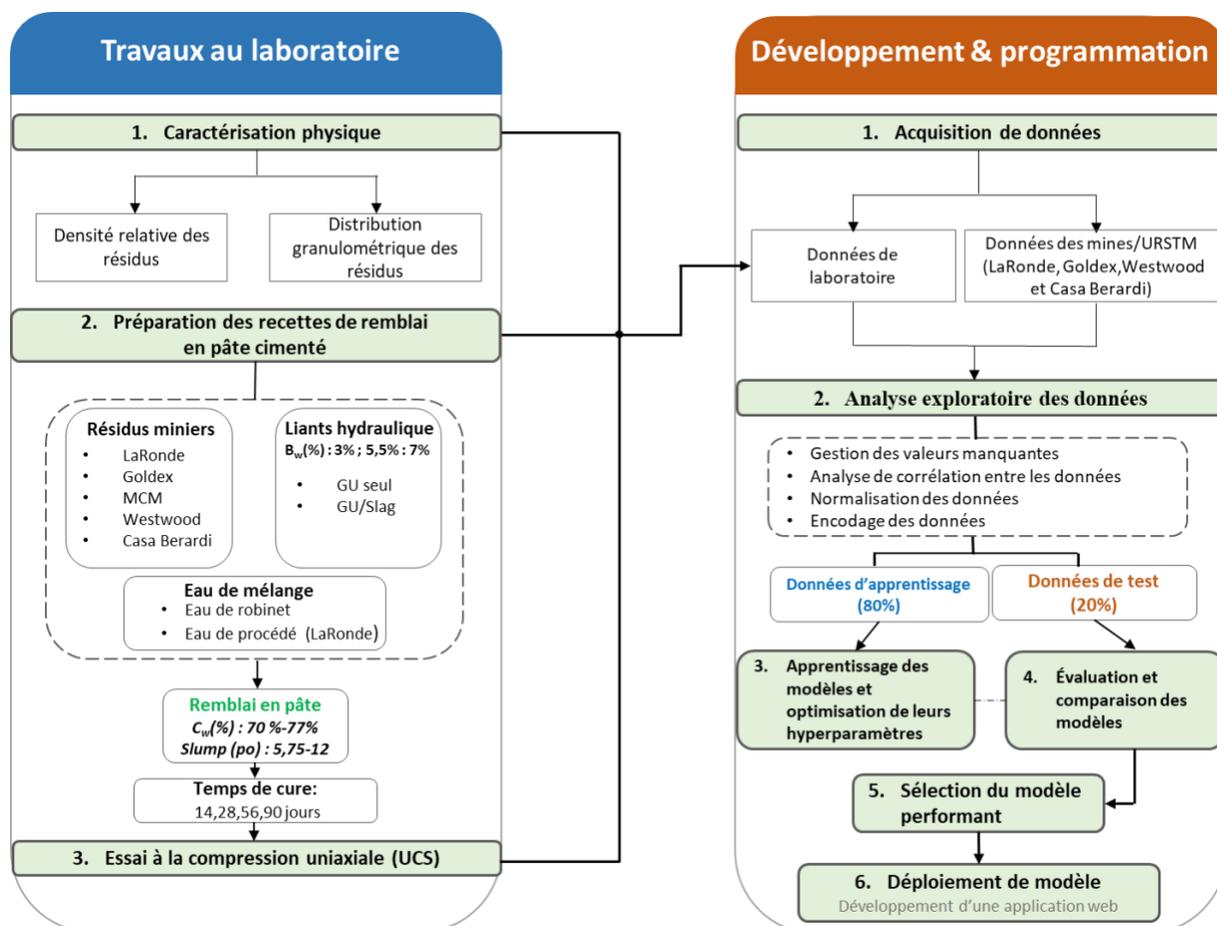


Figure 3-3 Démarche méthodologique générale de l'étude

3.3.1 Caractérisation physique des résidus

3.3.1.1 Teneur en eau massique et pourcentage solide des résidus

La teneur en eau massique initiale des résidus est un paramètre indispensable pour le calcul des mélanges de remblai en pâte. Après l'homogénéisation des résidus, un échantillon a été prélevé puis séché dans une étuve à une température de 60°C (pendant une durée de 48 heures environ) jusqu'à l'obtention d'une masse de l'échantillon constante après des mesures consécutives.

La teneur en eau massique w (%) se détermine par la relation suivante :

$$w(\%) = \frac{M_{th} - M_{ts}}{M_{ts} - M_t} \cdot 100 = \frac{M_w}{M_s} \cdot 100 \quad (3-1)$$

Avec M_{th} : masse humide avec la tare, M_{ts} : masse sèche avec la tare, M_t : masse de la tare, M_w : masse de l'eau et M_s : masse sèche.

Le pourcentage solide $C_w(\%)$ se déduit à partir de la teneur en eau massique par l'équation suivante :

$$C_w(\%) = \frac{M_{solide}}{M_{totale}} \cdot 100 = \frac{100}{100 + w(\%)} \cdot 100 \quad (3-2)$$

3.3.1.2 Densité relative des grains solides

La caractérisation physique de remblai en pâte cimenté se repose sur celle des résidus tandis que le liant ne présente pas un grand effet vu sa faible teneur dans le mélange par rapport au résidu.

La densité relative des grains des résidus miniers a été déterminée à l'aide d'un pycnomètre à hélium (Figure 3-4-a), selon la norme D854-10 (ASTM, 2012). Cet appareil mesure automatiquement la densité relative D_R à partir de la masse de l'échantillon (m_s connue). Un nombre d'exécutions de calcul (15 exécutions généralement) a été fait puis la densité relative se calcule par la moyenne. En effet, la densité des grains solides de l'échantillon est mesurée selon la formule suivante :

$$\rho_s = \frac{m_s}{V_s} \text{ (g/cm}^3\text{)} \quad (3-3)$$

Avec m_s et v_s représentent respectivement la masse et le volume des grains solides.

Puis la densité relative se détermine comme suit :

$$D_R = \frac{\rho_s}{\rho_{eau}} \quad (3-4)$$



Figure 3-4 Appareils de caractérisation physique des résidus : a) pycnomètre à hélium; b) granulomètre au laser Mastersizer 3000 de Malvern Panalytical

3.3.1.3 Distribution granulométrique

La distribution granulométrique est l'une des propriétés les plus cruciales à prendre en considération pour caractériser les résidus en vue de leur utilisation en tant que remblai en pâte. Il existe plusieurs méthodes d'analyse granulométrique, les plus répandues sont par sédimentométrie, par tamisage, et par granulométrie au laser.

L'analyse de la distribution granulométrique de tous les résidus dans cette étude a été effectuée à l'aide d'un granulomètre au laser Mastersizer[®] 3000 de Malvern Panalytical (Figure 3-4-b). Cet appareil permet de mesurer les particules dont la taille est comprise entre 0,05 et 900 µm. Le principe de détermination de taille des particules est basé sur le principe de diffraction ainsi que sur la diffusion d'un faisceau laser. Ce dernier traverse les particules puis il se diffracte en fonction d'un angle bien déterminé. La mesure de chaque angle de déviation sera interprétée par la suite pour calculer des diamètres des particules. Les résultats sont représentés sous forme d'une courbe semi-logarithmique. Les paramètres les plus importants pour caractériser la distribution des particules sont : le coefficient d'uniformité (C_U), le coefficient de courbure (C_C) et la proportion de particules ultrafines ayant un diamètre inférieur à 20 µm ($P_{20\mu m}$).

3.3.2 Calculs des mélanges

Il est important à retenir que le remblai en pâte cimenté est composé d'une phase solide (résidus et liant) mélangée avec une phase liquide (l'eau d'appoint). Avant le calcul des mélanges, il faut savoir : la teneur en eau massique de tous les résidus humide w (%) ainsi que leurs pourcentages solides ($C_{w-r\%}$), leurs densités relatives (G_s ou D_R), les proportions de liant ($B_w\%$) et les pourcentages solides visés de la pâte finale ($C_w\%$). Connaissant ces paramètres, on peut calculer la masse des résidus humides à prendre (M_{r-h}), la masse de liant (M_{liant}) et la masse d'eau à ajouter ($M_{eau \text{ à ajouter}}$) en utilisant les formules suivantes :

$$M_{r-h} = \frac{M_{r-s}}{C_{w-r}(\%)} \quad (3-5)$$

$$M_{liant} = B_w(\%) * M_{r-s} \quad (3-6)$$

$$M_{eau \text{ à ajouter}} = M_{eau \text{ tot}} - M_{eau-r} \quad (3-7)$$

Le calcul intermédiaire des masses de résidus secs (M_{r-s}), la masse totale de l'eau ($M_{eau\ tot}$) et la masse d'eau présente dans les résidus (M_{eau-r}) ont été calculés à l'aide d'une feuille Excel (Annexe A).

Après avoir calculé et dosé toutes les masses nécessaires des différents ingrédients de RPC (Figure 3-5-a), la masse de liant et une quantité de l'eau (le un quart de la masse de l'eau) sont versées puis pré-mélangées à l'aide d'une hélice afin d'activer la réaction d'hydratation de liant dans le grand récipient métallique du mélangeur Hobart (Figure 3-5-b). Ensuite, la masse des résidus est incorporée délicatement suivie par l'ajout de l'eau restant, mélangeant à une faible vitesse (vitesse 1) pendant 4 minutes. Une fois que l'eau se mélange bien avec les résidus, la vitesse 2 se lance pendant 30 secondes puis la vitesse 3 pendant 2 minutes jusqu'à l'obtention d'une pâte homogène.

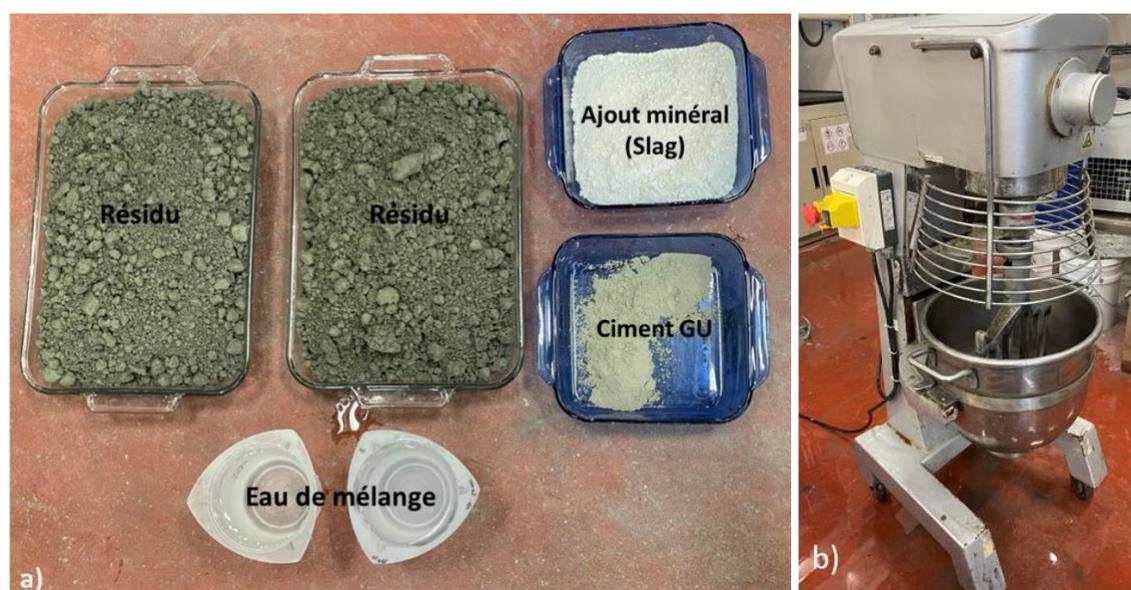


Figure 3-5 Préparation des mélanges : a) les ingrédients de RPC; b) mélangeur Hobart

3.3.3 Tests d'affaissement

Après avoir été bien mélangé le RPC, la consistance de la pâte finale a été déterminée à l'aide de l'essai de cône d'Abrams standard qui est la plus utilisé pour la fabrication des bétons, des mortiers et de RPC grâce à sa simplicité de mise en œuvre. Ce type de test est utilisé pour évaluer la faisabilité de pompage et le transport de remblai sous terre. Plus l'affaissement de la pâte est grand, plus facile sera son transport. Le principe de l'essai consiste à remplir le cône en trois couches égales pilonnées 25 fois par une tige métallique puis à soulever le cône délicatement (environ 4

secondes) comme le montre la Figure 3-7-a conformément à la norme ASTM C143 (ASTM International, 2020) de façon que le matériau soit soumis à son propre poids et il s'écoule sous l'effet de la contrainte résultante. Ensuite, la valeur de l'affaissement correspond à la différence entre la hauteur de cône et la hauteur de la pâte étalée (Figure 3-7-b).

L'affaissement mesuré est compris entre 5.75 et 10 pouces (146 et 254 mm) ce qui correspond à l'affaissement typique d'un remblai en pâte (Landriault et al., 1997).

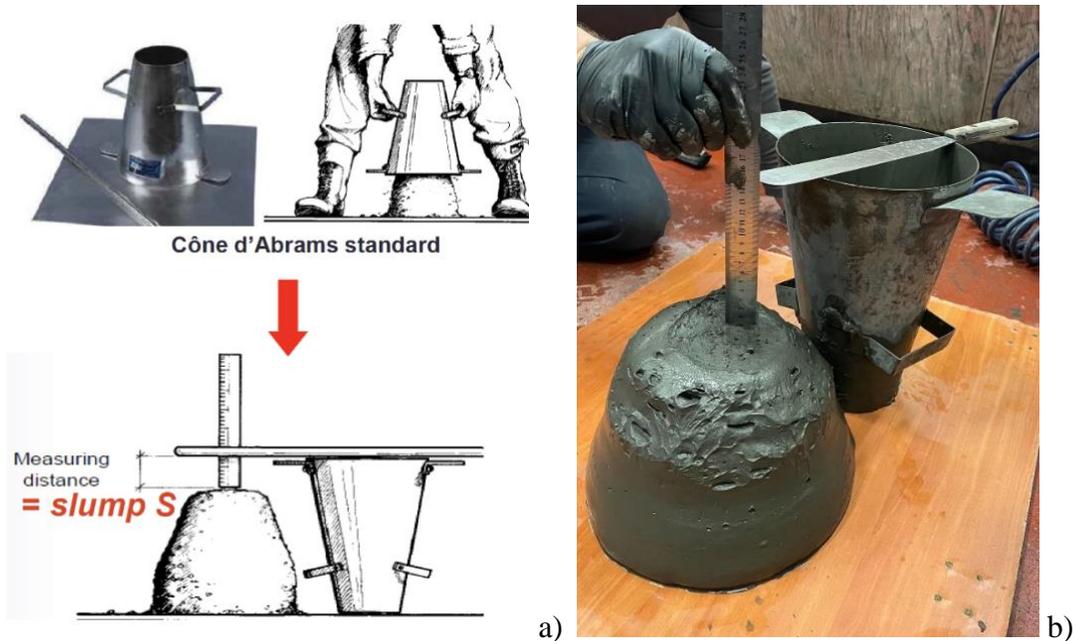


Figure 3-6 Mesure de l'affaissement à l'aide de la méthode standard du cône d'Abrams; a) au laboratoire, b) principe de mesure de l'affaissement

3.3.4 Préparation des éprouvettes de remblai

Dès que la mesure de l'affaissement des différents mélanges est terminée, ces derniers ont été versés dans des moules plastiques de 3 pouces (7.62 cm) de diamètre et 6 pouces (15.24 cm) de hauteur. Les moules ont été bien fermés puis entreposés dans une chambre humide ayant des conditions typiques similaires à celles des mines souterraines dont l'humidité relative est 90 % et la température à 23°C (Figure 3-7).

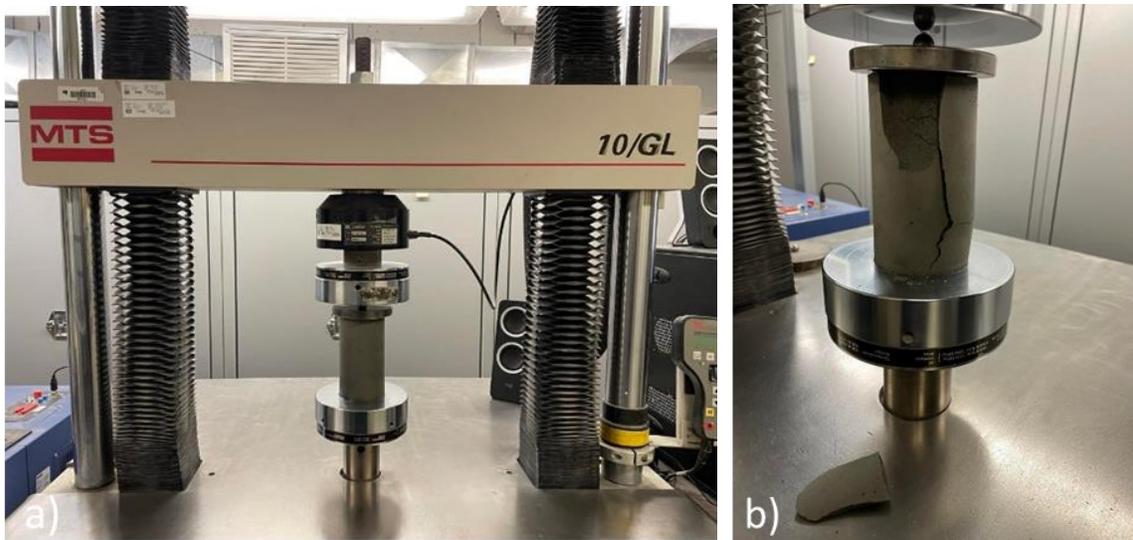


Figure 3-8 Essai de compression uniaxiale : a) presse mécanique rigide MTS 10/GL ; (b) échantillon cassé après l'essai

3.4 Méthodes intelligentes de prédiction de l'UCS

3.4.1 Collecte des données

Après avoir terminé l'essai de compression au laboratoire, on a pu de collecter 324 résultats d'UCS. D'autres résultats provenant de divers mines (Goldex, LaRonde, LZ5, Westwood) et des travaux de Sahi (2016) avec les résidus de Casa Berardi. On a pu construire une base de données de 10 050 formulations de remblais.

3.4.2 Analyse et prétraitement des données

Il faut savoir qu'on ne peut pas utiliser les bases de données qu'on a recueillies telles qu'elles sont. Une analyse et un prétraitement sont obligatoires, ce qu'on appelle en data science l'analyse exploratoire des données (*Exploratory Data Analysis* - EDA) en utilisant des méthodes de visualisation des données.

La *première étape* de ce processus, c'est de gérer les valeurs manquantes s'elles existent dans les bases de données. En effet, il y a plusieurs méthodes pour les manipuler, telles que le remplacement d'une donnée par la moyenne, la médiane ou par la valeur la plus fréquente ou autre valeur fixe. Mais la meilleure façon de faire, c'est de débarrasser de ces données pour n'est pas biaisé les modèles.

Dans notre cas d'étude, les données recueillies sont des données depuis l'année 2014 jusqu'à 2023. C'est pour cela qu'on a pas mal des données manquantes et la majorité de ces valeurs manquantes sont présentes dans les bases de données les plus anciennes. Donc, on a décidé de travailler avec les données depuis l'année 2019. D'une part les propriétés des résidus dans cette année ne sont pas trop variées par rapport à l'instant en comparant cette variation entre 2014 et 2023 et d'autre part une minorité des données manquantes dans ces bases de données depuis 2019 qui ont été supprimées.

En deuxième étape, les analyses univariées, bivariées et multivariées sont nécessaires pour savoir la fréquence de chaque donnée, pour comprendre comment une donnée affecte une autre et pour détecter également les valeurs aberrantes et les évaluer.

La dernière étape de ce processus consiste à transformer et normaliser les données afin de faciliter l'apprentissage des modèles. En outre, ces algorithmes ne fonctionnent qu'avec des données tabulaires, c'est la raison pour laquelle la transformation des données est une étape indispensable. Ce présent travail traite que des données numériques ce qui traduit par un problème de régression, pour d'autres problèmes de classifications (données catégorielles), il est possible d'appliquer des approches de transformation de données comme l'encodage binaire (*Binary encoding*), l'encodage d'états (*One-hot encoding*) et l'encodage étiqueté (*Ordinal encoding*).

En ce qui concerne la normalisation des données (*features scaling*), le but est de mettre toutes les données dans une même échelle. Supposons qu'une donnée a des valeurs inférieures à 10 et d'autres, supérieurs à 10 000, cette différence de valeur va affecter l'apprentissage des algorithmes de façon que les valeurs les plus élevées joueront un rôle plus décisif (supériorité) lors de l'apprentissage. Par conséquent cette normalisation doit être effectuée sur toutes les données afin de les mettre dans une plage de valeurs presque similaire et de réduire leur écart type. On trouve de nombreuses approches qui traitent cette normalisation, les plus courantes sont :

- Mise à l'échelle Min-Max « Min-Max Scaler » : consiste à redimensionner les données dans un intervalle compris en 0 et 1.

$$X_{scaler} = \frac{X - \min(X)}{\max(X) - \min(X)} \quad (3-8)$$

Cette méthode est efficace lorsque la distribution des données est non gaussienne, mais l'inconvénient est qu'elle est sensible aux valeurs aberrantes.

- Mise à l'échelle standard « StandardScaler » : cette approche permet de normaliser les données de façon qu'elles soient centrées autour de la moyenne et ayant un écart-type unitaire.

$$X_{scaler} = \frac{X - \mu}{\sigma} \quad (3-9)$$

Où μ et σ représentent respectivement la valeur moyenne et l'écart-type de la variable X . Cette méthode est efficace lorsque la distribution des données est gaussienne et elle est moins sensible aux valeurs aberrantes.

- Mise à l'échelle robuste « Robuste Scaler » : cette méthode est équivalente à la normalisation Min-Max, mais elle se base sur la valeur médiane et l'intervalle interquartile (IQR) pour normaliser les données.

$$X_{scaler} = \frac{X - X_{median}}{IQR} \quad (3-10)$$

$$IQR = Q_3 - Q_1 \quad (3-11)$$

où Q_3 , Q_1 représentent, respectivement, le troisième (75% des effectifs du variable X) et le premier quantile (25% des effectifs du variable X).

La robustesse de cette méthode réside au fait qu'elle est puissante pour les valeurs aberrantes.

- **Mise à l'échelle quantile « *Quantile Transformer* »** : c'est une méthode non linéaire qui transforme les données de façon que leurs fonctions de densité de probabilité soient mappées à une distribution gaussienne. Cette méthode réduit considérablement les valeurs aberrantes.

Pour ce projet, les deux méthodes *Quantile Transformer* et Min-Max Scaler seront utilisées pour normaliser nos données.

3.4.3 Critères de choix des modèles

Il est vrai que dans l'apprentissage automatique (*Machine Learning*) et également dans l'apprentissage profond (*Deep Learning*) on trouve plusieurs algorithmes différents (régression logistique, les arbres de décisions, les supports vecteurs machine, la méthode des k plus proches voisins, les forêts aléatoires ou même les réseaux de neurones, etc.). Mais il est difficile de faire le choix entre tous ces modèles. Cependant, il existe des critères de choix qui permettent de sélectionner un ou plusieurs modèles selon le type de projet.

En première partie, avant de décider de s'engager dans l'apprentissage automatique (ou l'apprentissage profond), il est indispensable d'évaluer la quantité des données, autrement dit décidé si la base de données qu'on a est suffisante pour entraîner des modèles de ML. Si par exemple on a 50 échantillons, donc ce n'est pas intéressant d'implémenter des modèles de ML, dans ce cas de simples modèles mathématiques de régression peuvent répondre au besoin. En revanche, si on dispose beaucoup de données (même plus de 3 000 échantillons), on pourra les exploiter pour l'apprentissage automatique.

En seconde partie, la structure des données définit le type des modèles de ML (ou DL) à utiliser. En effet, pour les données non structurées (données catégorielles) comme les images, le son et les textes, il est conseillé de développer des réseaux de neurones artificiels (les réseaux de neurones convolutifs ou les réseaux de neurones récurrents). Pour les données structurées (des données numériques ou également des données tabulaires), divers algorithmes disponibles sont efficaces pour résoudre soit des problèmes de régression soit des problèmes de classification. Pour des problèmes de classifications, le choix de l'algorithme dépend également du type l'apprentissage automatique utilisé. Autrement dit, s'il agit de l'apprentissage supervisé ou l'apprentissage non supervisé.

Un autre critère à prendre en considération, c'est la normalité des données. En effet, en ML il existe deux types de modèle : des modèles paramétriques (régression linéaire, régression logistique et Naive Bayes, etc..) qui ont des paramètres limités et définis à l'avance et qui fonctionnent généralement pour des données ayant des distributions normales. Au contraire les modèles non paramétriques ont des paramètres non limités et non définis à l'avance (arbre de décision, les forêts aléatoires). Ce genre de modèles fonctionnent bien avec des données ayant des distributions

quelconques. C'est la raison pour laquelle il faut analyser la distribution des données avant de les exploiter.

Le nombre des variables quantitatives (et qualitatives) représente aussi un critère pour choisir un modèle. Dans le cas où il a plusieurs variables dans une base de données, il est recommandé de travailler avec des modèles basés sur les forêts aléatoires. La carte des algorithmes de *scikit-learn* (Figure 3-9) résume tous ces critères et suggère des algorithmes selon la quantité et la qualité des données.

Il convient de noter qu'il n'a pas un modèle qui performe plus qu'un autre, il faut tester plein d'algorithmes après avoir limité le champ de choix des algorithmes. En effet, on ne peut pas dire qu'un tel modèle dédié pour un tel problème, au contraire un modèle peut s'entraîner différemment sur deux bases de données différentes.

De plus, il arrive qu'un modèle donne de moyennes performances, voire faibles, mais il faudra juste l'améliorer par l'optimisation de leurs hyperparamètres. Donc, même après l'implémentation des modèles de ML, l'évaluation des performances et le suivi de l'apprentissage des modèles est une étape indispensable, car il ne faut pas oublier aussi qu'il y a les phénomènes de surajustement (*overfitting*) et le sous-ajustement (*underfitting*).

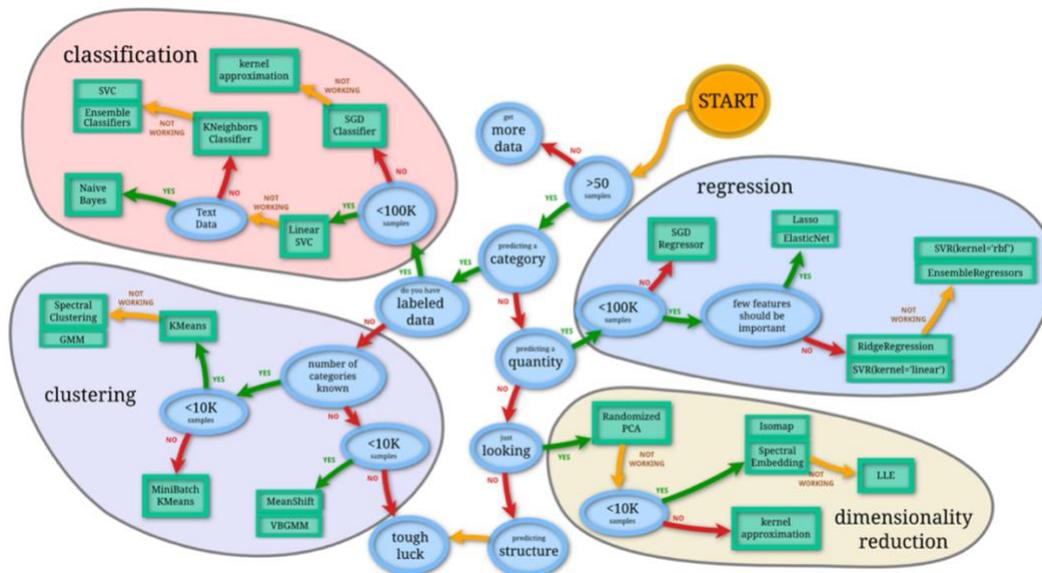


Figure 3-9 Carte des algorithmes de la bibliothèque de Python Scikit-learn (Mathivet, 2021)

On ne se limite pas à ce niveau pour choisir nos algorithmes, car il est nécessaire de comprendre la théorie derrière chaque modèle, leurs forces et leurs faiblesses. Dans ce contexte, trois grandes théories de ML (théorie d'ensemble) permettent de développer des modèles très puissants à savoir la théorie ensembliste en parallèle « *Bagging* » et la théorie ensembliste en série « *Boosting* » et le « *Stacking* ». L'idée générale réside à la combinaison des modèles individuels moins performants (les arbres de décision) afin de minimiser les biais et les variances de chacun pour avoir un modèle plus performant.

- Le *Bagging* : cette approche consiste à créer plusieurs entités d'un même modèle (arbre de décision) et les entraîner de façon indépendante (en parallèle) sur des portions aléatoires de la base de données à l'aide du technique « *Bootstrapping* ». Elle consiste à replacer après chaque tirage les données qui ont été sélectionnées et à la fin regrouper la prédiction de chaque modèle pour avoir la prédiction finale (vote maximum pour des problèmes de classification et valeur moyenne pour des problèmes de régression). Les modèles individuels entraînés sont relativement forts, mais qu'ils sont sujets de surapprentissage. Après les avoir combinés, le modèle final est fiable et permet de réduire la variance.
- Le *Boosting* : À l'inverse du *Bagging*, cette méthode consiste à entraîner des entités d'un modèle l'une après l'autre d'une façon dépendante et séquentielle (en série) de telle sorte que les faiblesses des uns sont compensées par les forces des autres. À chaque fois qu'un nouveau modèle s'entraîne, il corrige les erreurs effectuées par son prédécesseur. Les modèles individuels entraînés sont relativement faibles, mais qu'ils sont sujets de sous-apprentissage. Après avoir les combiner, le modèle final est fiable et permet de réduire le biais.
- Le *Stacking* : cette technique consiste à entraîner un métamodèle de ML par-dessous les prédictions faites par d'autres algorithmes, pour lui-même prédire le résultat final. Les modèles initiaux entraînés peuvent être des modèles basés sur le *Bagging* ou le *Boosting*. Cette technique permet d'améliorer la précision de prédiction.

En se basant sur les critères mentionnés ci-dessus, les modèles qui vont être utilisés dans cette étude sont : les forêts aléatoires (*Random Forest* - RF) qui sont basé sur les arbres de décisions, l'algorithme de descente de gradient pour la régression (*Gradient Boosting Regressor* - GBR),

l'algorithme de la descente de gradient extrême pour la régression (*eXtreme Gradient Boosting Regressor* - XGBR) et un réseau de neurones profonds (*Deep Neural Network* - DNN) et plus précisément le réseau de propagation vers l'arrière (*Feed-Forward Back Propagation Network* - FFBN).

3.4.4 Decision Tree (DT)

Il s'agit d'un algorithme en *Machine Learning* qui s'appuie sur les arbres décisionnels et qui utilise certaines règles pour prédire une valeur cible et peut résoudre des problèmes linéaires ou non linéaires. En fait, c'est une structure arborescente (Figure 3-10) constituée de nœud racine, des nœuds de décisions, des nœuds de feuilles (terminal) et des niveaux de profondeur. Elle parvient à faire une estimation en posant des questions aux données et chaque question réduit les valeurs possibles au fur et à mesure afin que le modèle soit assez fiable pour faire des prédictions (Ronowicz et al., 2015). Pour les problèmes de régression, l'algorithme de minimisation pour un arbre utilise la somme des erreurs quadratiques, définie comme suit:

$$s = \sum_{c \in \text{feuilles}} \sum_{i \in c} (y_i - m_c)^2 \quad (3-12)$$

Où $m_c = \frac{1}{n_c} \sum_{i \in c} y_i^*$ est la prédiction pour la feuille c , n_c est le nombre d'échantillons dans la feuille et y_i^* est la sortie du $i^{\text{ème}}$ échantillon de l'ensemble de données.

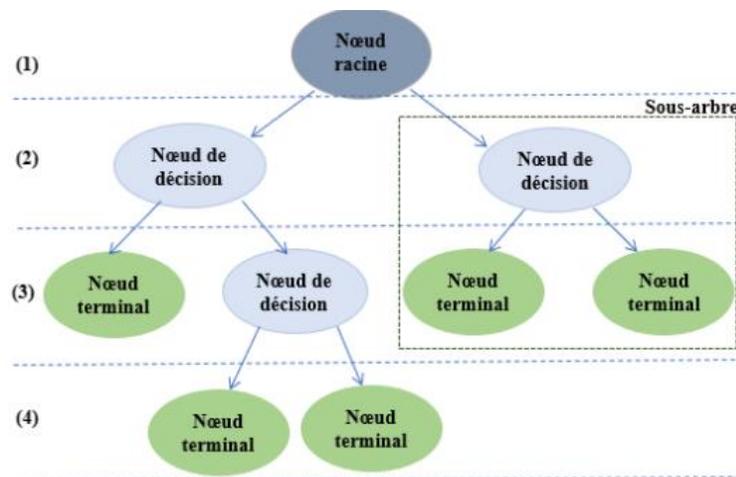


Figure 3-10 Structure d'un arbre décisionnel

Puisqu'il s'agit d'un modèle d'apprentissage automatique supervisé, l'arbre de décision est conçu pour corrélérer les données d'entrée aux sorties, ce qui représente la phase d'apprentissage du modèle. Au cours de son entraînement, il se produit un arbre qui traduit les questions en valeurs selon les données d'entrée ainsi que l'ordre de passage d'un niveau à autre afin de faire des estimations plus précises. Au cours de ce processus, le DT peut être fortement affecté par des valeurs aberrantes et avoir une capacité de généralisation relativement mauvaise.

Pour prédire une nouvelle valeur, il suffit donc de fournir au modèle le même format des données sur lesquelles il a été entraîné. Ces données traversent l'arborescence jusqu'à ce qu'elles atteignent le nœud terminal. En fin, la prédiction est la moyenne de la valeur de la variable dépendante dans ce nœud terminal; on peut dire donc que les arbres de décision généralement ne font que des approximations intelligentes des plus proches voisins. L'avantage de ce modèle est qu'il est facile à comprendre, à interpréter et visualiser des résultats à partir de celui-ci, mais l'inconvénient majeur est qu'il est sujet au surajustement. Le DT a été largement utilisé en génie civil, notamment pour la prédiction de la stabilité des pentes (Qi et al., 2018), la prédiction de l'éclatement des roches (Zhou et al., 2016) et l'évaluation de la résistance des roches (Liang et al., 2016). Lu et al. (2019) et Qi et al. (2018) ont exploités cet algorithme pour prédire la résistance à la compression uniaxiale de remblais en pâte cimentés.

Comme mentionné, l'inconvénient majeur de cet algorithme est qu'il a souvent la tendance à être en surajustement. C'est pour cette raison que l'algorithme des forêts aléatoire (*Random Forest*) est conçu à améliorer les performances de l'algorithme DT sur la base de la théorie de Bagging.

3.4.5 Random Forest (RF)

C'est un algorithme très populaire en ML, qui permet d'utiliser plusieurs arbres de décision afin d'avoir une forêt d'arbres. Il repose sur la technique du « *Bagging* » qui consiste à entraîner chaque arbre sur une partie aléatoire de la base de données, ce qui justifie le nom forêts aléatoires « *Random Forest* », puis à combiner toutes les prédictions de tous les arbres en faisant la moyenne pour aboutir à une prédiction plus fiable et plus stable que celle obtenue avec des arbres de décision individuels.

Vu qu'il se base sur le « *Bootstrapping* » pour échantillonner les données, un échantillon peut être entraîné plusieurs fois sur de différents arbres de décisions et pour assurer de meilleures

performances, il est utile de diversifier les échantillons. Le principal avantage de ce modèle est qu'il permet d'avoir une réduction de surajustement nettement importante en faisant la moyenne de prédiction de plusieurs arbres, il est meilleur que le « *Decision Tree Regressor* » au niveau de généralisation et de flexibilité. Mais, il est plus lent en calcul et inefficace pour les prédictions en temps réel. Depuis son adoption, le RF a été utilisé pour résoudre un grand nombre de problèmes de prédiction, y compris la prédiction de la profondeur de rupture des galeries souterraines (Qi and Chen, 2018), la prédiction de la stabilité des pentes (Lin et al., 2018), la classification des éclatements rocheux (Lin et al., 2018) et l'analyse du tassement du sol induit par les tunnels (Zhou et al., 2017), ainsi que pour la prédiction de l'UCS des RPC (Qi et al., 2018; Lu et al., 2019).

3.4.6 Gradient Boosting Regressor (GBR)

C'est l'un des algorithmes le plus robuste dans l'apprentissage automatique qui a été implémenté dans plusieurs applications d'ingénierie (Lu et al., 2019; Qi et al., 2018a; Zhou et al., 2016). Il est basé sur l'implémentation des arbres de forêt et sur la technique de « *Boosting* » qui consiste à construire et à entraîner des arbres l'un après l'autre, sachant que la performance de chacune est relativement faible. En revanche, grâce à son algorithme d'optimisation « La descente de gradient », chaque arbre corrige l'erreur effectuée par son prédécesseur, donc avec cette méthode on obtient un modèle complètement complémentaire dans lequel les faiblesses des uns sont compensées par les forces des autres. L'algorithme commence tout d'abord à créer une feuille qui contient la valeur moyenne des données d'entrée sur lesquelles il a été entraîné, ensuite il va créer le premier arbre en tenant en compte de l'erreur de prédiction de la première feuille. En se basant sur l'erreur de ce premier arbre, le *Gradient Boosting* créera un nouvel arbre et ainsi de suite jusqu'à avoir une erreur de prédiction réduite. Donc, il est capable de corriger les erreurs de prédiction arbre après arbre (Figure 3-11). Avec ce processus, on arrive à créer itérativement tous les arbres de forêt et le résultat final pour une nouvelle prédiction est défini par la moyenne de prédiction de tous les arbres. Une explication plus approfondie de cet algorithme est détaillée dans (Friedman, 2001).

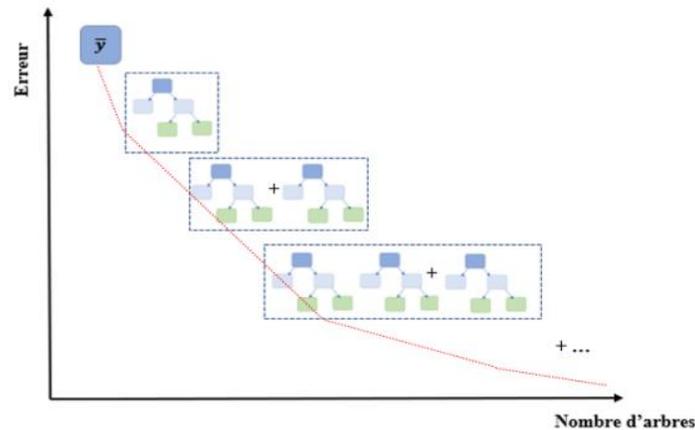


Figure 3-11 Évolution de l'erreur en fonction de nombre d'arbres

3.4.7 eXtreme Gradient Boosting Regressor (XGBR)

Il s'agit d'une optimisation de l'algorithme « *Gradient Boosting Regressor* » pour être flexible, efficace et portable. Il est de même basé sur l'implémentation des arbres de décision et sur le « *Boosting* ». En fait, des arbres sont développés l'un après l'autre et des démarches de réduction du taux d'erreur sont effectuées lors des itérations successives. La première étape d'algorithme est l'entraînement sur la base de données pour obtenir une première prédiction, ensuite le résidu est calculé par la différence entre la valeur réelle et la valeur prédite. Le premier arbre est alors développé en l'entraînant sur ces résidus afin de les minimiser, puis un deuxième arbre se créera de la même manière et ainsi de suite jusqu'à ce qu'élaborer un arbre n'a pas d'effet sur les performances de l'algorithme. En effet, lors de la construction des arbres, l'algorithme calculera dans chaque arbre un score de similarité et la valeur de sortie de chaque nœud de décision dans le but d'améliorer la performance de chaque arbre.

La différence entre XGBR et GBR réside au niveau de processus l'amélioration d'apprentissage. En effet, GBR utilise la dérivée partielle de premier ordre (gradient de premier ordre) de la fonction perte pour ajuster le processus d'apprentissage alors que le XGBR utilise les gradients de second ordre, ainsi que la méthode de régularisation L1&L2 pour l'amélioration du modèle à se généraliser (Chen and Guestrin, 2016). C'est pour cette raison qu'on trouve souvent que le XGBR développe des performances meilleures que le GBR.

3.4.8 Réseau de neurones artificiels (ANN)

Les réseaux de neurones artificiels sont inspirés du cerveau de l'être humain (Figure 3-12-a), à l'intérieur duquel il existe plein de neurones biologiques. Son fonctionnement repose sur la réception des informations par les dendrites, ensuite les neurones transmettent ces informations sous forme d'impulsions à travers l'axone et puis passent par les synapses et vont jusqu'à autres neurones.

Alors, les réseaux de neurones artificiels représentent des modèles prédictifs. Ils sont constitués d'une couche d'entrées, un ou plusieurs couches cachées et une couche de sortie. Toutes les couches sont connectées entre eux et les neurones dans la même couche fonctionnent d'une manière indépendante. Chaque neurone est connecté au neurone qu'il précède et celui qu'il suit et il possède des paramètres tels que le poids, le biais ainsi que le seuil à partir duquel le neurone transmette l'information.

Les données sont émises aux neurones d'entrées, puis elles traversent toutes les couches cachées et enfin la couche de sortie pour corréler les entrées aux sorties dans le but d'entraîner le modèle. Les neurones comparent la somme pondérée des entrées à un seuil et fournissent une réponse à la sortie. Les informations se transmettent d'un neurone à un autre par une fonction d'activation. L'erreur de prédiction est améliorée par l'ajustement des poids entre les nœuds (Shovic and Simpson, 2021).

Cependant, les réseaux neuronaux sont pour la plupart des boîtes noires. L'inspection de leurs caractéristiques ne nous permet pas de comprendre la manière dont ils résolvent un problème, et il est parfois difficile de former des réseaux neuronaux de grande taille. Le perceptron est le réseau de neurones le plus simple qui a été inventé par Frank Rosenblatt en 1958, il est constitué d'un seul neurone unique à n entrées. Ce perceptron constitue réellement une fonction mathématique. Les entrées à ce neurone seront multipliées par des poids w_i et additionnées avec un biais associé à ce neurone. Ce dernier s'active pour transmettre l'information (sortie y) au neurone dans la couche suivante, si la sortie a dépassé le seuil défini dans la fonction d'activation comme le montre la Figure 3-12-b.

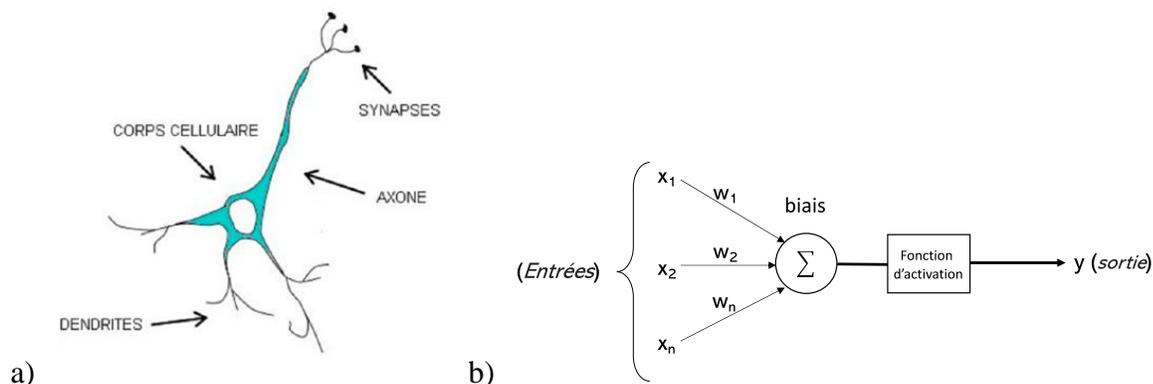


Figure 3-12 (a) Neurone biologique, (b) Neurone artificiel (Lacombe, 2018)

Donc un réseau de neurones profond (DNN), ce n'est qu'un ensemble de perceptrons interconnectés de la première couche d'entrées jusqu'à la couche de sortie par l'intermédiaire des couches cachées. Il existe divers types de réseaux de neurones, les plus courants en apprentissage profond sont les réseaux à propagation vers l'avant qui sont les plus adoptés au traitement du langage naturel (*Natural Language Processing* - NLP), les réseaux de neurones convolutifs (CNN) qui sont utilisés pour la reconnaissance d'image et pour la vision par ordinateur et les réseaux de neurones récurrents (RNN) qui se caractérisent par des boucles de retour d'information. Ce type de réseau s'utilise principalement lors du traitement de données de séries temporelles et au NLP.

Dans la présente étude, un réseau de neurones sera appliqué pour prédire l'UCS de RPC, plus précisément le modèle séquentiel de l'API Keras. Comme son nom l'indique, l'implémentation de ce réseau se fait d'une façon séquentielle, autrement dit couche après couche. Ce réseau de neurones est capable de faire l'apprentissage par supervision (classification ou régression) sur la base des données d'apprentissage. En effet, son apprentissage se fait principalement en deux grandes étapes : la propagation vers l'avant (*Forward propagation*) et la propagation vers l'arrière (*Back propagation*) comme le montre la Figure 3-13.

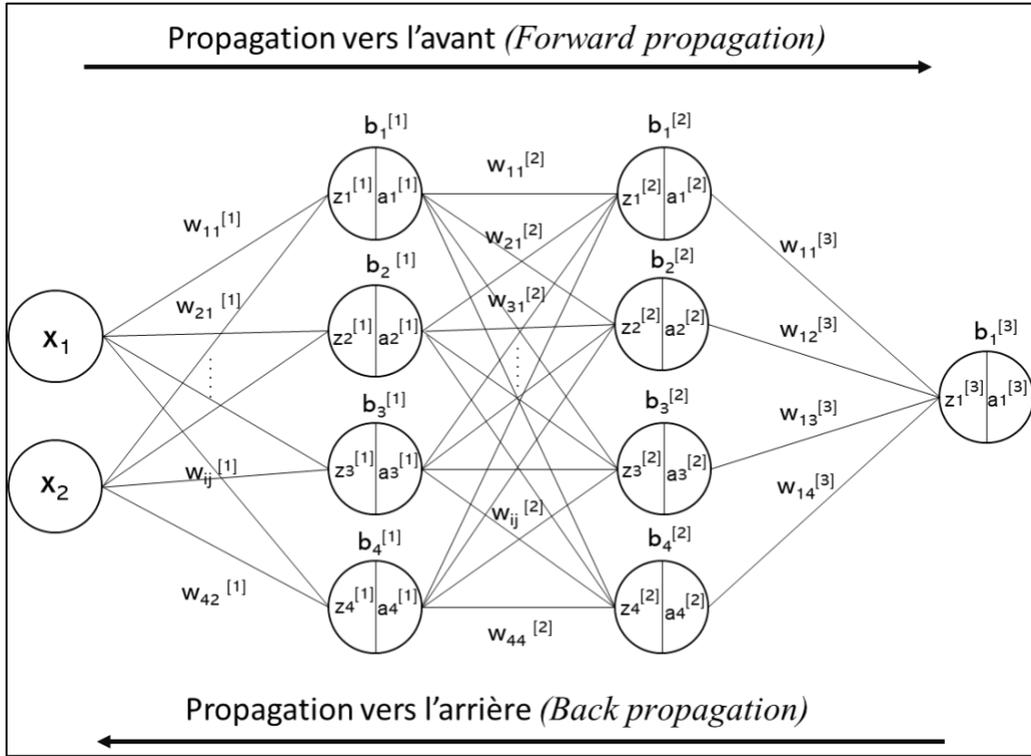


Figure 3-13 Réseau de neurones à rétropropagation vers l'arrière (*Feed-Forward Back Propagation Network-FFBPN*)

Le processus de la propagation vers l'avant (*Forward propagation*) consiste à faire passer toutes les données d'entrées de la première couche jusqu'à la dernière en calculant à chaque couche les sorties (z) et les fonctions d'activation $a = f(z)$ associés à chaque neurone. Cela permet la transformation de la donnée d'entrées à travers le réseau (Amini et al., 2018; Grus, 2020; Shovic and Simpson, 2021).

Les sorties de la première couche cachée se calculent comme suit:

$$z_1^{[1]} = x_1 \cdot w_{11}^{[1]} + x_2 \cdot w_{12}^{[1]} + b_1^{[1]} \quad (3-13a)$$

$$z_2^{[1]} = x_1 \cdot w_{21}^{[1]} + x_2 \cdot w_{22}^{[1]} + b_2^{[1]} \quad (3-13b)$$

$$z_3^{[1]} = x_1 \cdot w_{31}^{[1]} + x_2 \cdot w_{32}^{[1]} + b_3^{[1]} \quad (3-13c)$$

$$z_4^{[1]} = x_1 \cdot w_{41}^{[1]} + x_2 \cdot w_{42}^{[1]} + b_4^{[1]} \quad (3-13d)$$

Pour la deuxième couche cachée :

$$z_1^{[2]} = w_{11}^{[2]} \cdot a_1^{[1]} + w_{12}^{[2]} \cdot a_2^{[1]} + w_{13}^{[2]} \cdot a_3^{[1]} + w_{14}^{[2]} \cdot a_4^{[1]} + b_1^{[2]} \quad (3-14a)$$

$$z_2^{[2]} = w_{21}^{[2]} \cdot a_1^{[1]} + w_{22}^{[2]} \cdot a_2^{[1]} + w_{23}^{[2]} \cdot a_3^{[1]} + w_{24}^{[2]} \cdot a_4^{[1]} + b_2^{[2]} \quad (3-14b)$$

$$z_3^{[2]} = w_{31}^{[2]} \cdot a_1^{[1]} + w_{32}^{[2]} \cdot a_2^{[1]} + w_{33}^{[2]} \cdot a_3^{[1]} + w_{34}^{[2]} \cdot a_4^{[1]} + b_3^{[2]} \quad (3-14c)$$

$$z_4^{[2]} = w_{41}^{[2]} \cdot a_1^{[1]} + w_{42}^{[2]} \cdot a_2^{[1]} + w_{43}^{[2]} \cdot a_3^{[1]} + w_{44}^{[2]} \cdot a_4^{[1]} + b_4^{[2]} \quad (3-14d)$$

Avec $a_i^{[n]} = f(z)$ est la fonction d'activation de neurone (i) dans la couche (n)

Pour la couche de sortie :

$$z_1^{[3]} = w_{11}^{[3]} \cdot a_1^{[2]} + w_{12}^{[3]} \cdot a_2^{[2]} + w_{13}^{[3]} \cdot a_3^{[2]} + w_{14}^{[3]} \cdot a_4^{[2]} + b_1^{[3]} \quad (3-15)$$

Après la vectorisation des équations de la première couche, on obtient :

$$Z^{[1]} = \begin{bmatrix} Z_1^{[1]} \\ Z_2^{[1]} \\ Z_3^{[1]} \\ Z_4^{[1]} \end{bmatrix} = \begin{bmatrix} w_{11}^{[1]} & w_{12}^{[1]} \\ w_{21}^{[1]} & w_{22}^{[1]} \\ w_{31}^{[1]} & w_{32}^{[1]} \\ w_{41}^{[1]} & w_{42}^{[1]} \end{bmatrix} \cdot \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} b_1^{[1]} \\ b_2^{[1]} \\ b_3^{[1]} \\ b_4^{[1]} \end{bmatrix} \quad (3-16a)$$

$$Z^{[1]} = W^{[1]} \cdot X + b^{[1]} \quad (3-16b)$$

$$A^{[1]} = f(Z^{[1]}) = \begin{bmatrix} a_1^{[1]} \\ a_2^{[1]} \\ a_3^{[1]} \\ a_4^{[1]} \end{bmatrix} \quad (3-16c)$$

Après la vectorisation des équations de la deuxième couche, on obtient :

$$Z^{[2]} = \begin{bmatrix} Z_1^{[2]} \\ Z_2^{[2]} \\ Z_3^{[2]} \\ Z_4^{[2]} \end{bmatrix} = \begin{bmatrix} w_{11}^{[2]} & w_{12}^{[2]} & w_{13}^{[2]} & w_{14}^{[2]} \\ w_{21}^{[2]} & w_{22}^{[2]} & w_{23}^{[2]} & w_{24}^{[2]} \\ w_{31}^{[2]} & w_{32}^{[2]} & w_{33}^{[2]} & w_{34}^{[2]} \\ w_{41}^{[2]} & w_{42}^{[2]} & w_{43}^{[2]} & w_{44}^{[2]} \end{bmatrix} \cdot \begin{bmatrix} a_1^{[1]} \\ a_2^{[1]} \\ a_3^{[1]} \\ a_4^{[1]} \end{bmatrix} + \begin{bmatrix} b_1^{[2]} \\ b_2^{[2]} \\ b_3^{[2]} \\ b_4^{[2]} \end{bmatrix} \quad (3-17a)$$

$$Z^{[2]} = W^{[2]} \cdot A^{[1]} + b^{[2]} \quad (3-17b)$$

$$A^{[2]} = f(Z^{[2]}) = \begin{bmatrix} a_1^{[2]} \\ a_2^{[2]} \\ a_3^{[2]} \\ a_4^{[2]} \end{bmatrix} \quad (3-17c)$$

Après la vectorisation d'équation de la dernière couche, on obtient :

$$Z^{[3]} = [z_1^{[3]}] = [w_{11}^{[3]} \quad w_{12}^{[3]} \quad w_{13}^{[3]} \quad w_{14}^{[3]}] \cdot \begin{bmatrix} a_1^{[2]} \\ a_2^{[2]} \\ a_3^{[2]} \\ a_4^{[2]} \end{bmatrix} + b_1^{[3]} \quad (3-18a)$$

$$Z^{[3]} = W^{[3]} \cdot A^{[2]} + b^{[3]} \quad (3-18b)$$

Finalement pour généraliser le calcul pour un réseau de neurones profonds (avec plusieurs couches cachées):

$$z_i^{[l]} = \sum_{j=1}^n w_{i,j}^{[l]} \cdot a_j^{[l-1]} + b_i^{[l]} \quad (3-19a)$$

$$a_i^{[l]} = f^{[l]}(z_i^{[l]}) \quad (3-19b)$$

Avec $w_{i,j}^{[l]}$ représente le poids du $i^{\text{ème}}$ neurone et du $j^{\text{ème}}$ entrée dans l' $i^{\text{ème}}$ couche cachée.

Le processus de la propagation vers l'arrière (*Back propagation*) consiste en premier lieu à définir une fonction de perte ($\varphi = f(A)$), généralement « l'erreur quadratique moyenne ». Cette fonction permet d'évaluer les erreurs du modèle et prend en compte la sortie du réseau. En deuxième lieu, le processus consiste à calculer les dérivées partielles de cette fonction pour comprendre son évolution par rapport aux paramètres du réseau (les poids w_{ij} et les biais b_i) de la dernière couche du réseau jusqu'à la première couche. En dernier lieu, ce processus met à jour ces paramètres de manière à minimiser la fonction perte (les erreurs du modèle) par le calcul de ses dérivées partielles par rapport au poids et au biais de chaque couche (Éqns 3-2- et 3-21). Tout le calcul est bien détaillé dans (Amini et al., 2018).

$$\frac{\partial \varphi}{\partial W^{[n]}} = \frac{\partial \varphi}{\partial A^{[n]}} \cdot \frac{\partial A^{[n]}}{\partial Z^{[n]}} \cdot \frac{\partial Z^{[n]}}{\partial W^{[n]}} \quad (3-20)$$

$$\frac{\partial \varphi}{\partial b^{[n]}} = \frac{\partial \varphi}{\partial A^{[n]}} \cdot \frac{\partial A^{[n]}}{\partial Z^{[n]}} \cdot \frac{\partial Z^{[n]}}{\partial b^{[n]}} \quad (3-21)$$

Comme il est mentionné précédemment, les données d'entrées se transforment lorsqu'elles traversent le réseau de neurones afin de produire un résultat. Ces transformations sont dues au processus de la propagation vers l'avant, plus précisément par les calculs de chaque neurone par l'intégration de ses propres attributs. Bien que le poids et le biais soient définis aléatoirement à tous les neurones, la fonction d'activation est l'attribut qui se définit manuellement pour chaque

couche cachée par le concepteur du réseau. En effet, cette fonction d'activation joue le rôle d'une porte (ouvert ou fermée) qui détermine si l'information va se transmettre au neurone suivant (activation du neurone actuel) ou non (désactivation du neurone actuel).

Il existe différents types de fonctions d'activation, les plus couramment utilisés dans un réseau de neurones pour des problèmes de régression et classifications sont :

- **La fonction d'activation d'unité linéaire rectifiée (Rectified Linear Unit – ReLU) :**

C'est une fonction linéaire qui permet d'introduire un filtre à la sortie de la couche, qui permet de ne faire passer que les valeurs positives et bloque les valeurs négatives.

$$f(z) = \max(0, z) \quad (3-22)$$

Ce qui traduit par :

$$\begin{aligned} f(z) &= z & \text{si } z > 0 \\ f(z) &= 0 & \text{sinon} \end{aligned}$$

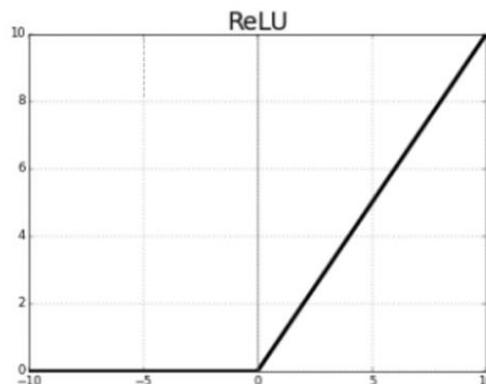


Figure 3-14 Fonction d'activation ReLU (Farhadi, 2017)

- **La fonction d'activation Sigmoïde ou logistique**

Cette fonction est généralement dédiée aux problèmes de classification binaire. Elle se place souvent en dernière couche du réseau de neurones. Réellement, c'est une fonction probabiliste qui suit une loi de Bernoulli; elle renvoie donc des valeurs entre 0 et 1.

Elle s'écrit comme suit :

$$f(z) = \frac{1}{1+e^{-z}} \quad (3-23)$$

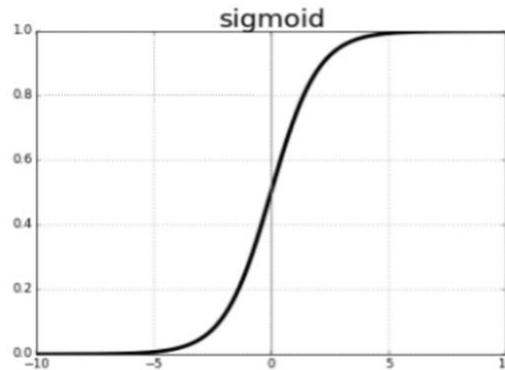


Figure 3-15 Fonction d'activation Sigmoide (Farhadi, 2017)

▪ **La fonction d'activation Softmax**

C'est la forme la plus généralisée de la fonction sigmoïde. Pour des problèmes multi-classes, la fonction sigmoïde n'est pas applicable vu qu'elle donne à chaque élément une valeur entre 0 et 1, ce qui ne respecte pas la loi de probabilité lorsque tous les éléments s'additionnent. C'est pour cette raison la fonction Softmax est utilisée pour ce genre de problèmes.

Comme la fonction sigmoïde, elle renvoie des valeurs comprises entre 0 et 1. Elle s'écrit comme suit :

$$f(z) = \frac{e^z}{\sum_i e^{z_i}} \quad (3-24)$$

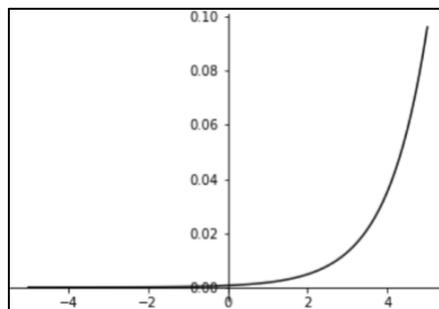


Figure 3-16 Fonction d'activation Softmax (Farhadi, 2017)

▪ **La fonction d'activation tangente hyperbolique (tanh)**

La fonction *tanh* est destinée à normaliser les valeurs d'entrée dans l'intervalle $[-1,1]$, elle peut s'appliquer dans n'importe quelle couche du réseau.

Sa fonction mathématique s'écrit :

$$f(z) = \frac{\sin z}{\cos z} = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (3-25)$$

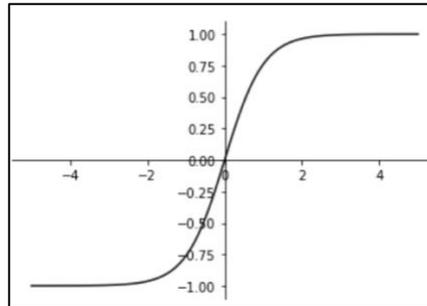


Figure 3-17 Fonction d'activation tangente hyperbolique (Farhadi, 2017)

Les fonctions d'activation des couches cachées et de la couche de sortie dépendent respectivement de type de réseau de neurones lui-même (Perceptron multicouche - MLP, réseau de neurones convolutifs ou réseau de neurones récurrents) et du problème que le réseau traiterait (problème de régression ou problème de classification). Certains réseaux de neurones normalisent les données à la première couche cachée, dont les fonctions d'activation sigmoïde et *tanh* sont généralement appliquées. Les fonctions d'activations de la couche de sortie dépendent aussi de la variable cible à prédire; s'il s'agit d'une prédiction d'une variable quantitative et c'est la fonction linéaire (ReLU) qui doit être utilisée. Cependant, pour une prédiction d'une variable catégorielle, c'est les deux fonctions *softmax* et sigmoïde qui peuvent être utilisées.

Dans notre cas d'étude, ces fonctions seront sélectionnées par un algorithme de recherche qu'on expliquera plus tard dans le chapitre des résultats et discussions.

3.5 Récapitulatif

Dans ce chapitre, on a bien identifié les matériaux qu'on a utilisés pour préparer les différentes formulations de remblai en pâte ainsi que les démarches pour la caractérisation des résidus et la caractérisation mécanique du RPC. Les différentes étapes de prétraitement des données collectées ont été bien décrites. Le critère de choix des modèles intelligents pour prédire l'UCS des RPC ainsi que leurs théories ont été bien détaillées également.

CHAPITRE 4 RÉSULTATS ET DISCUSSION

4.1 Introduction

Ce chapitre présente les résultats de cette étude. Tout d'abord, les résultats des travaux de laboratoire seront présentés, à savoir la distribution granulométrique des résidus, les résultats des essais à la compression. Ensuite, tous les résultats de programmation seront illustrés, dont une analyse exploratoire des données bien détaillées en incluant la distribution, la corrélation et la normalisation des données. Les résultats du développement et d'optimisation des hyperparamètres des modèles de ML et le réseau de neurones profonds (DNN) seront également présentés. L'évaluation et la comparaison de leurs performances seront faites afin de sélectionner le modèle le plus performant qui sera par la suite opérationnel par la création d'une application web.

4.2 Résultats expérimentaux

4.2.1 Distribution granulométrique des résidus

Les résultats des analyses granulométriques de tous les résidus utilisés dans ce projet sont illustrés dans la Figure 4-1. Ces courbes nous permettent d'avoir une idée sur la finesse de résidus. Le tableau 4-1 présente également quelques paramètres granulométriques essentiels qu'on peut déterminer à partir de la courbe granulométrique. Il est possible de déterminer le diamètre des grains D_x correspond à $x\%$ passant.

Il faut noter que les résidus miniers sont classés dans la catégorie granulométrique des silts, pour avoir de bonnes résistances de remblai en pâte, les résidus doivent montrer des courbes granulométriques étalées. Dans notre cas d'étude, les résidus se caractérisent par un D_{10} entre $3\ \mu\text{m}$ et $5\ \mu\text{m}$, un D_{50} entre $18\ \mu\text{m}$ et $40\ \mu\text{m}$ et un D_{90} entre $87\ \mu\text{m}$ et $165\ \mu\text{m}$.

Le coefficient d'uniformité C_U de tous les résidus est supérieur à 2 (même supérieur à 5), ce qui traduit par une granulométrie pseudo-bien étalée. À l'exception des résidus de Casa Berardi, le coefficient de courbure de tous les résidus est supérieur à 1. Ce qui montre que ces résidus sont gradués et peuvent développer de bonnes résistances. On peut conclure que les caractéristiques de tous les résidus appartiennent à la gamme typique de courbes de distribution granulométrique de 11 résidus échantillonnés dans des mines de roches dures canadiennes (Yilmaz et al., 2011).

La proportion des particules ultrafines $P_{20\mu\text{m}}$ ($d < 20 \mu\text{m}$) joue un rôle très important au niveau de développement de résistance de RPC. La proportion recommandée de ces particules dans les RPC est inférieure à 15% (Landriault, 1995). Les résidus utilisés dans ce projet ayant des valeurs de $P_{20\mu\text{m}}$ supérieur à 30% qui vont affecter les résistances de RPC.

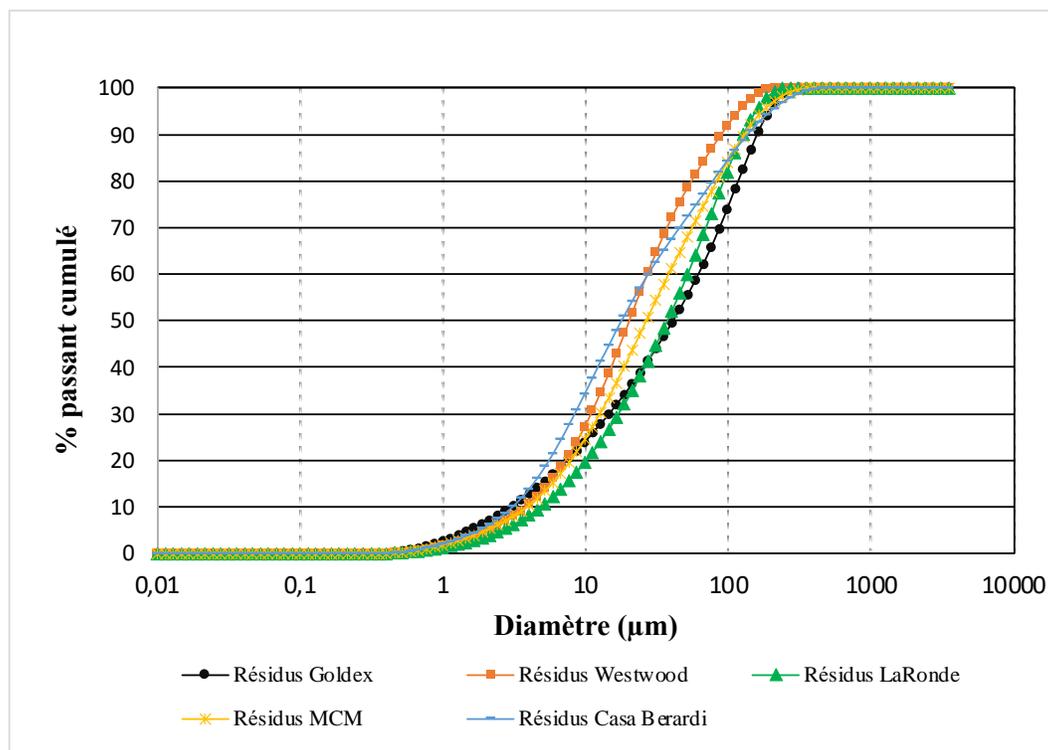


Figure 4-1 Courbes granulométriques des résidus testés

Tableau 4-1 Paramètres physiques des résidus testés

Type de résidus	w (%)	C_w (%)	G_s	$D_{10}(\mu\text{m})$	$D_{60}(\mu\text{m})$	C_c	C_u	$P_{20\mu\text{m}}$ (%)
LaRonde	23,5	81	3,18	4,87	52	1,14	10,68	33
Westwood	23,39	79,1	2,823	3,84	27	1,15	7,03	48
Goldex	16,69	85,7	2,796	3,01	61,7	1,15	20,5	35
Malartic	20,3	83,1	2,763	3,9	38,2	1,07	9,79	42
Casa Berardi	23,1	81,2	2,966	3,08	27,5	0,83	8,93	51
LZ5	25,5	79,7	2,91	3,2	17,9	1	5,6	63,9

4.2.2 Essais de compression uniaxiale

Après avoir placé correctement l'échantillon entre les deux plateaux de la presse mécanique, le chargement est appliqué sur l'éprouvette jusqu'à l'apparition des fissures où l'essai s'arrête automatiquement. Le chargement appliqué lors de la rupture de l'éprouvette, rapporté à l'aire de sa section, donne la valeur de la résistance à la compression uniaxiale (UCS). Au cours de l'essai, un système d'acquisition enregistre l'évolution du chargement appliqué en fonction du déplacement axiale (Figures 4-2 et 4-3). Le Tableau 4-2 indique les différentes caractéristiques de l'échantillon telles que l'UCS, le module de Young, la déformation axiale, pour les trois échantillons E1 à E3 de chaque mélange. Les résistances à la compression uniaxiale des mélanges obtenus étaient comprises entre 32 et 4176 kPa; ce qui est attendu pour le remblai en pâte cimenté.

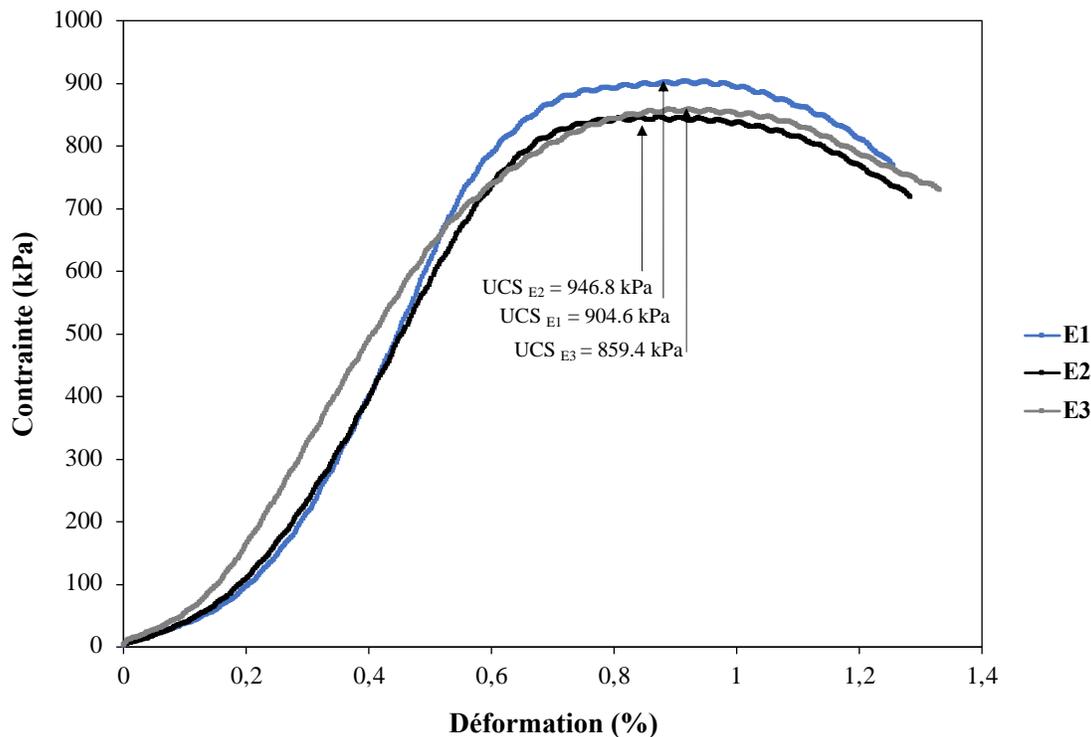


Figure 4-2 Courbes contrainte-déformation pour le mélange 30GU/70Slag à 3% liant avec les résidus de LaRonde et à 28 jours de cure

4.2.3 Facteurs influençant l'UCS du remblai en pâte cimenté

4.2.3.1 Effet du type de liant et de sa proportion sur l'UCS

Les histogrammes de la Figure 4-4 présentent une comparaison des résistances de RPC obtenues avec les résidus de LaRonde avec différents pourcentages de ciment pour trois temps de cure. Chaque valeur d'UCS représente la valeur moyenne obtenue à partir des trois essais en indiquant leurs écarts-types. À court terme (14 jours) et avec un faible pourcentage de liant (3%), les mélanges faits avec un liant 30GU/70Slag ont développé les bonnes résistances. Cela est dû à la dominance de l'hydratation rapide du ciment Portland (GU) lors du contact avec l'eau pendant les périodes précoces.

On peut distinguer plus cette différence au niveau des résultats des mélanges faits avec les résidus de Casa Berardi (Figure 4-4d) où les bonnes résistances ont été obtenues à sept jours pour le mélange fait avec le ciment Portland seul. Toutefois, à long terme (105 jours) on remarque que le mélange fait avec le ciment composé 20GU/80Slag donne les résistances les plus élevées.

En augmentant le pourcentage de liant, on voit clairement l'effet de la Slag où on peut remarquer que les résistances élevées sont obtenues pour les mélanges à base de liant (10GU/90Slag et 20GU/80Slag). À moyen terme (à partir de 56 jours), les résistances sont meilleures avec ces deux derniers liants composés.

Ceci s'explique par le retard de la réaction d'hydratation du Slag par rapport le ciment Portland GU. Grâce à des éléments pouzzolaniques qu'il contient, la réaction du Slag résulte la formation du gel portlandite (C-S-H) qui à son tour augmente la résistance.

D'autres résultats des résistances des RPC réalisées avec les résidus de Westwood, Goldex et MCM sont similaires à ceux obtenus avec les résidus de LaRonde sont présentés dans l'Annexe-B. Ces résultats ont été trouvés également par (Sahi, 2016).

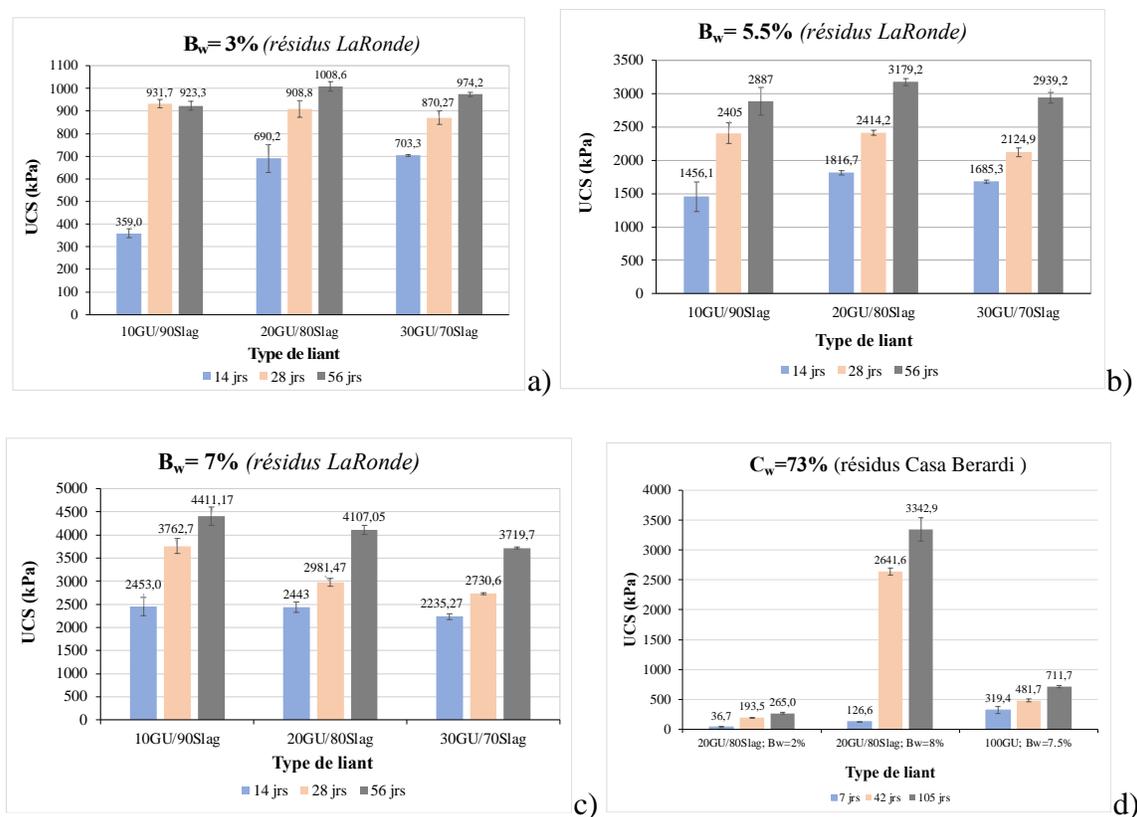


Figure 4-4 Variation de l'UCS selon le type de liant GU/Slag

La Figure 4-5 représente l'évolution de l'UCS en fonction de temps et pourcentage de liant. Il est évident que toutes les résistances de mélanges s'améliorent d'une part en fonction de temps cure et d'autre part en augmentant le pourcentage ciment. Ce qui se traduit par l'augmentation de la cohésion et la diminution de l'angle de frottement (Belem et al., 2000).

Ces variations dépendent de type des résidus utilisés du fait que la présence des sulfures dans les résidus affecte la microstructure des hydrates formés et par conséquent la résistance à la compression. Vu qu'on a utilisé divers résidus ayant chacun une teneur en sulfure, l'effet de liant est différent d'un résidu à un autre et par conséquent l'évolution de l'UCS en fonction de liant ne semble pas la même pour tous les mélanges (Annexe-B).

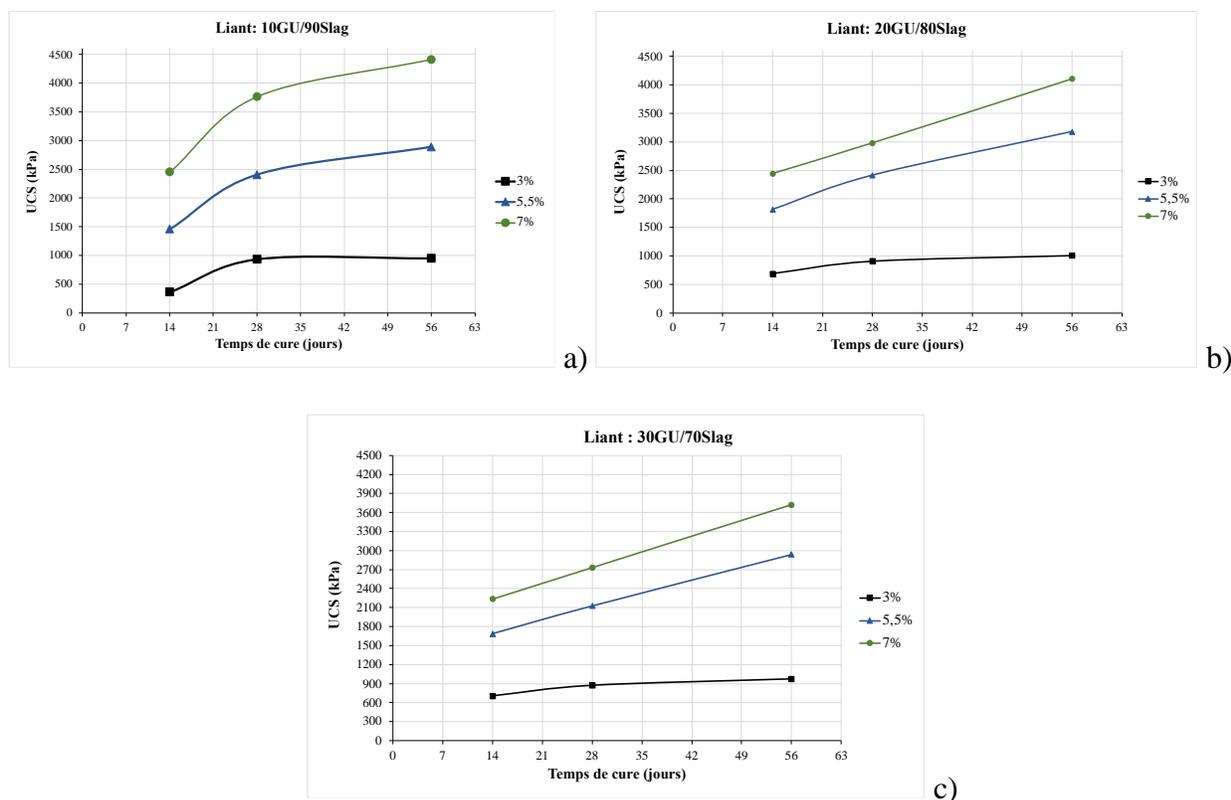


Figure 4-5 Variation de l'UCS en fonction de temps et pourcentage de liant avec les résidus de LaRonde

4.2.3.2 Effet des caractéristiques physique des résidus sur l'UCS

La Figure 4-6-a représentent l'évolution de l'UCS selon le type des résidus. En se basant sur ses caractérisations physiques, on peut remarquer que les résistances les plus élevées ont été obtenus avec les résidus de LaRonde. Cela est dû au faible pourcentage des particules fines ayant un diamètre inférieur à 20 μm dans ces résidus ($P_{20\mu\text{m}} = 32\%$) par rapport à ceux dans les résidus de Goldex et MCM qui sont respectivement égales à 35% et 42%.

En effet, pour le même type de liant et avec un pourcentage de solides et pourcentages de liant données, les mélanges de RPC réalisées à partir des résidus ayant une faible proportion des fines (résidus LaRonde) gagnent davantage en résistance que ceux obtenus à partir de résidus ayant une proportion élevée de fines (résidus MCM). Ceci est dû au fait que la finesse affecte la porosité globale de la pâte de remblai, dont le volume des espaces vides entre les particules est plus petit dans les remblais fabriqués à partir de résidus ayant une porosité faible (faible proportion des fines) que ceux obtenus à partir de résidus ayant une porosité élevée autrement dit une forte proportion

des fines (Belem et al., 2000a; Fall et al., 2004). En d'autres termes, le $P_{20\mu m}$ affecte le besoin en eau, car pour une consistance donnée, les résidus fins nécessitent plus d'eau que les résidus moyens et grossiers. Comme il mentionné à la Figure 4-6-a, les résidus de MCM ont donnée l'affaissement le plus faible, cela signifie que ces résidus ont consommée plus d'eau ce qui rend la pâte de remblai très humide et aura une faible densité et par conséquent une faible résistance. Dans la Figure 4-7, on peut voir clairement la diminution de la résistance de RPC lorsque le pourcentage des particules fines augmente.

Afin de bien justifier l'effet de $P_{20\mu m}$, on compare les résistances obtenus à partir des résidus de LZ5 (résultats provenant des mines) ayant une forte proportion des fines ($P_{20\mu m} \cong 64\%$). La Figure 4-6b montre églament pour un même pourcentage de liant, ces résidus ont donné les plus faibles résistances aux RPC malgré que ces échantillons ont été fabriquées avec le plus fort pourcentage de solide. Les résistances obtenues avec les résidus de Goldex cette fois-ci est plus élevées que ceux obtenus avec LaRonde dû au fort pourcentage solide.

Non seulement la proportion des fines affecte la résistance, mais aussi la densité relative des résidus. En effet l'augmentation de cette dernière augmente la consommation de liant en volume. Ce qui permet aux mélanges de remblais préparés avec les résidus de LaRonde (G_s plus élevée) d'avoir les résistances les plus élevées. Toutefois, une forte densité relative se traduit par une forte teneur en soufre dans les résidus qui affecte la cinétique d'hydratation de l'agent liant, ce qui permet l'augmentation de la consommation du pourcentage volumique de liant.

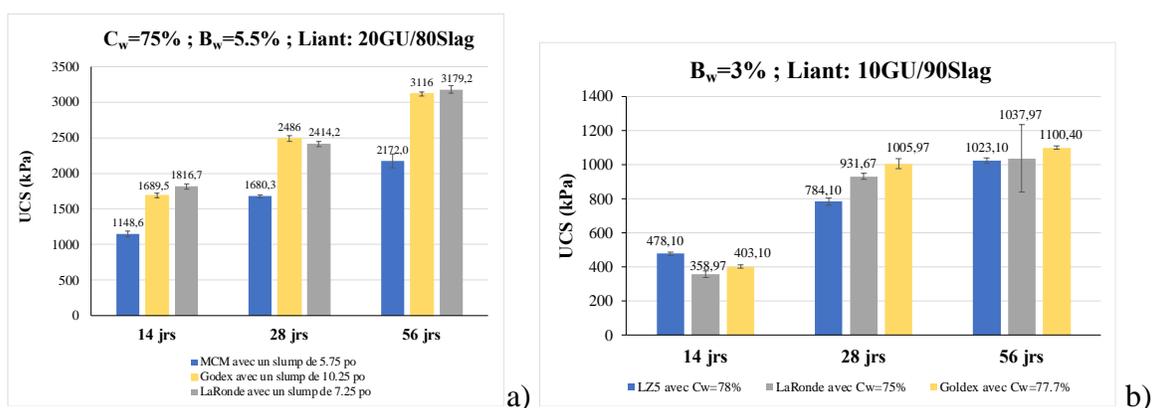


Figure 4-6 Variation de l'UCS selon le type de résidus

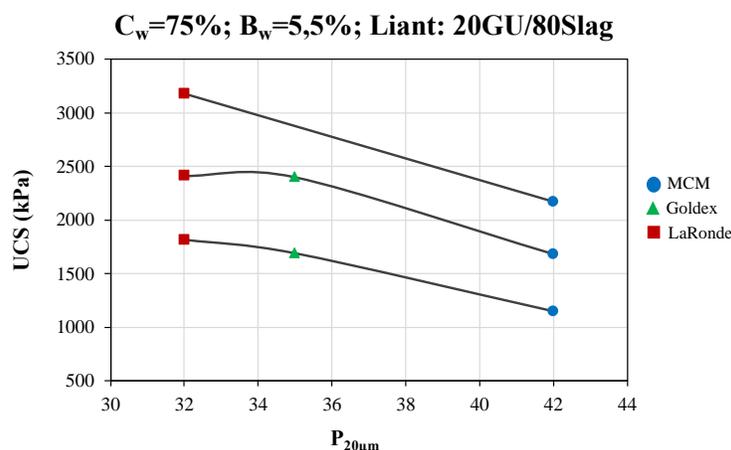


Figure 4-7 Variation de l'UCS en fonction de $P_{20\mu m}$ des résidus

4.3 Résultats de programmation et développement

4.3.1 Analyse exploratoire des données (*Exploratory data analysis - EDA*)

L'analyse exploratoire des données est une approche en data science permettant d'analyser des ensembles de données, et visant à résumer leurs principales caractéristiques, généralement à l'aide de méthodes visuelles. L'EDA nous permettent d'avoir une première impression des données, ce qui nous permet de déterminer si les données ont un sens, ou si un nettoyage plus approfondi ou davantage de données sont nécessaires. Cette analyse nous aide également à identifier des modèles et des tendances dans les données (ceux-ci peuvent être tout aussi importants que les résultats de la modélisation).

Deux grandes techniques pour l'EDA à savoir les sommaires statistiques (statistique inférentielle, statistique descriptive) et la visualisation des données (histogrammes pour la distribution des données, des courbes de tendances pour la corrélation entre différentes données et diagrammes en boîte à moustaches pour la distribution et l'identification des valeurs aberrantes). Ces méthodes sont utilisées pour analyser notre base de données.

4.3.1.1 Distribution des données

Rappelons que le but de cette étude est de prédire l'UCS de RPC par des modèles intelligents en se basant sur des données historiques. Afin que ces modèles puissent se généraliser correctement sur de nouvelles données, il est nécessaire d'avoir des données d'apprentissage diversifiées. La

Figure 4-8 représente le nombre des essais à la compression uniaxiale par type de résidus. Bien que les résidus de Goldex occupent presque 75% des données, il existe d'autres données intéressantes sur d'autres résidus. Il faut savoir aussi que la difficulté majeure des projets de science des données est la collecte des données et plus précisément les données sur les RPC. Donc, on peut dire à ce niveau que notre base de données est exploitable, mais elle nécessite plus d'analyse et de traitement, ce qui sera l'objectif du reste de ce chapitre.

La première chose à vérifier dans une base de données, ce sont les valeurs manquantes. Ici on a remarqué la présence de quelques-uns. La Figure 4-9a représente la base de données avec des valeurs manquantes (tous ce qui est en blanc). La manière la plus adéquate pour gérer ces valeurs, c'est de les supprimer pour ne pas biaiser l'apprentissage des modèles. La Figure 4-9b représente notre base de données après nettoyage des valeurs manquantes.

Pour approfondir notre analyse, on a représenté les distributions en histogrammes de chaque donnée. On trouve comme variable, les propriétés physique des résidus (G_s , C_u , C_c et $P_{20\mu m}$), leurs propriétés minéralogiques (les teneurs en muscovite, en pyrite, en silicates et en sulfures), leurs propriétés chimiques (les teneurs en Ca, en Mg, en S et en Zn), la teneur en sulfate dans l'eau, le type de liant utilisé (Ciment GU, le laitier de haut fourneau ou encore le Slag, les cendres volantes ou encore le *fly ash* de type C et F), le pourcentage de liant $B_w(\%)$, le pourcentage solide $C_w(\%)$, l'affaissement de la pâte finale de remblai ou encore le Slump (po), le temps de cure et la résistance à la compression uniaxiale.

La Figure 4-10 représente les distributions de toutes les données. À partir de celle-ci, on remarque que les variables n'ont pas une distribution ni gaussienne ni uniforme (ce sont des distributions quelconques). Ceci nous permet de s'écarter aux modèles linéaires de prédiction et de choisir après une méthode d'analyse de corrélation appropriée.

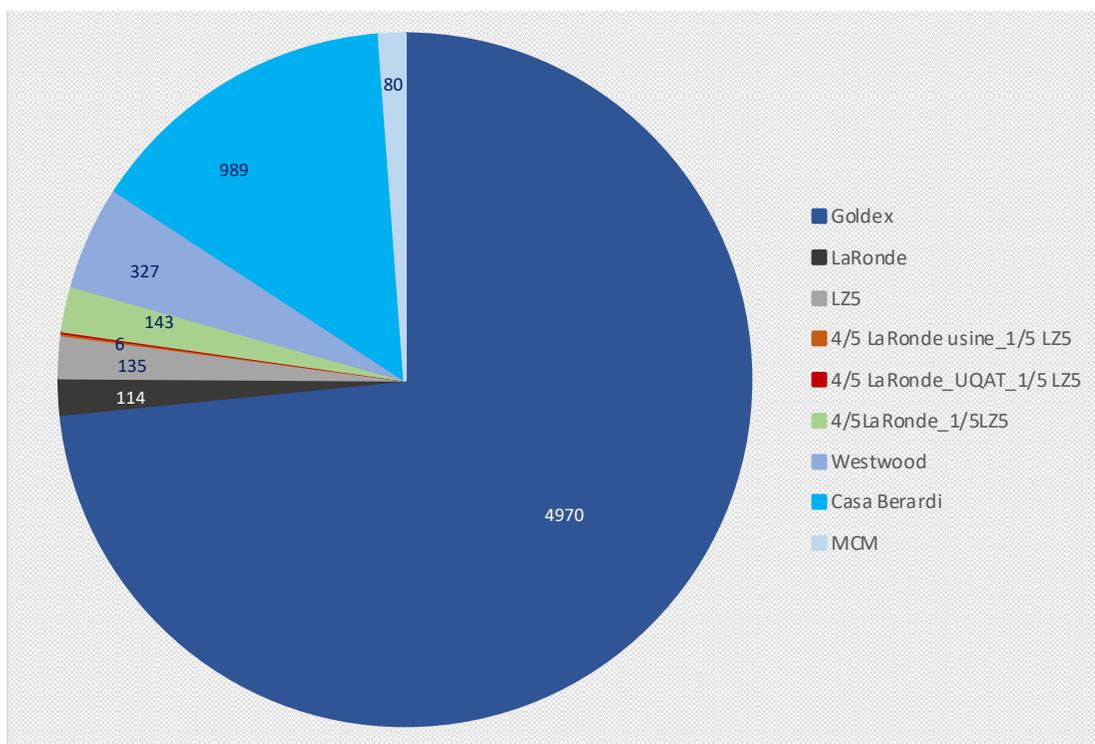


Figure 4-8 Distribution des mélanges de RPC dans la base de données selon le type de résidus

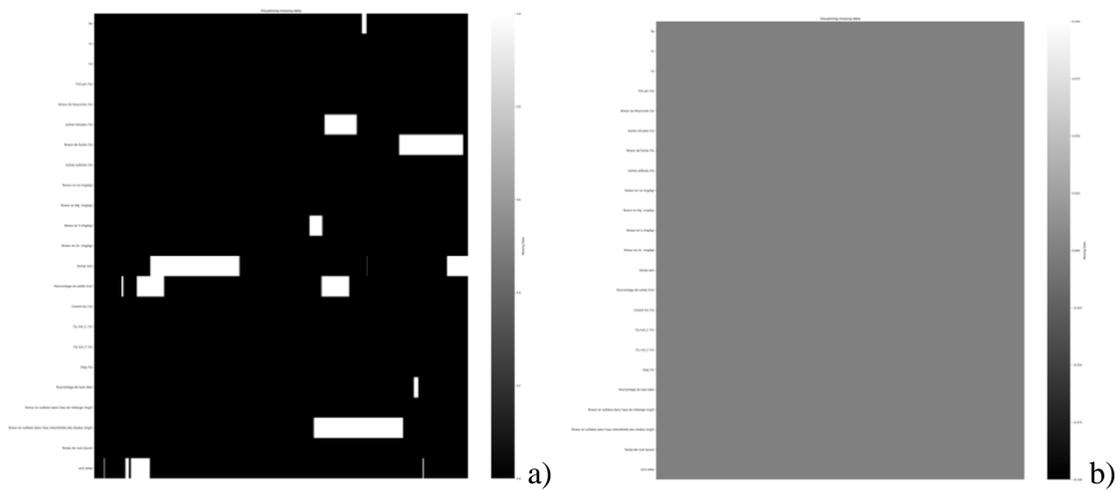
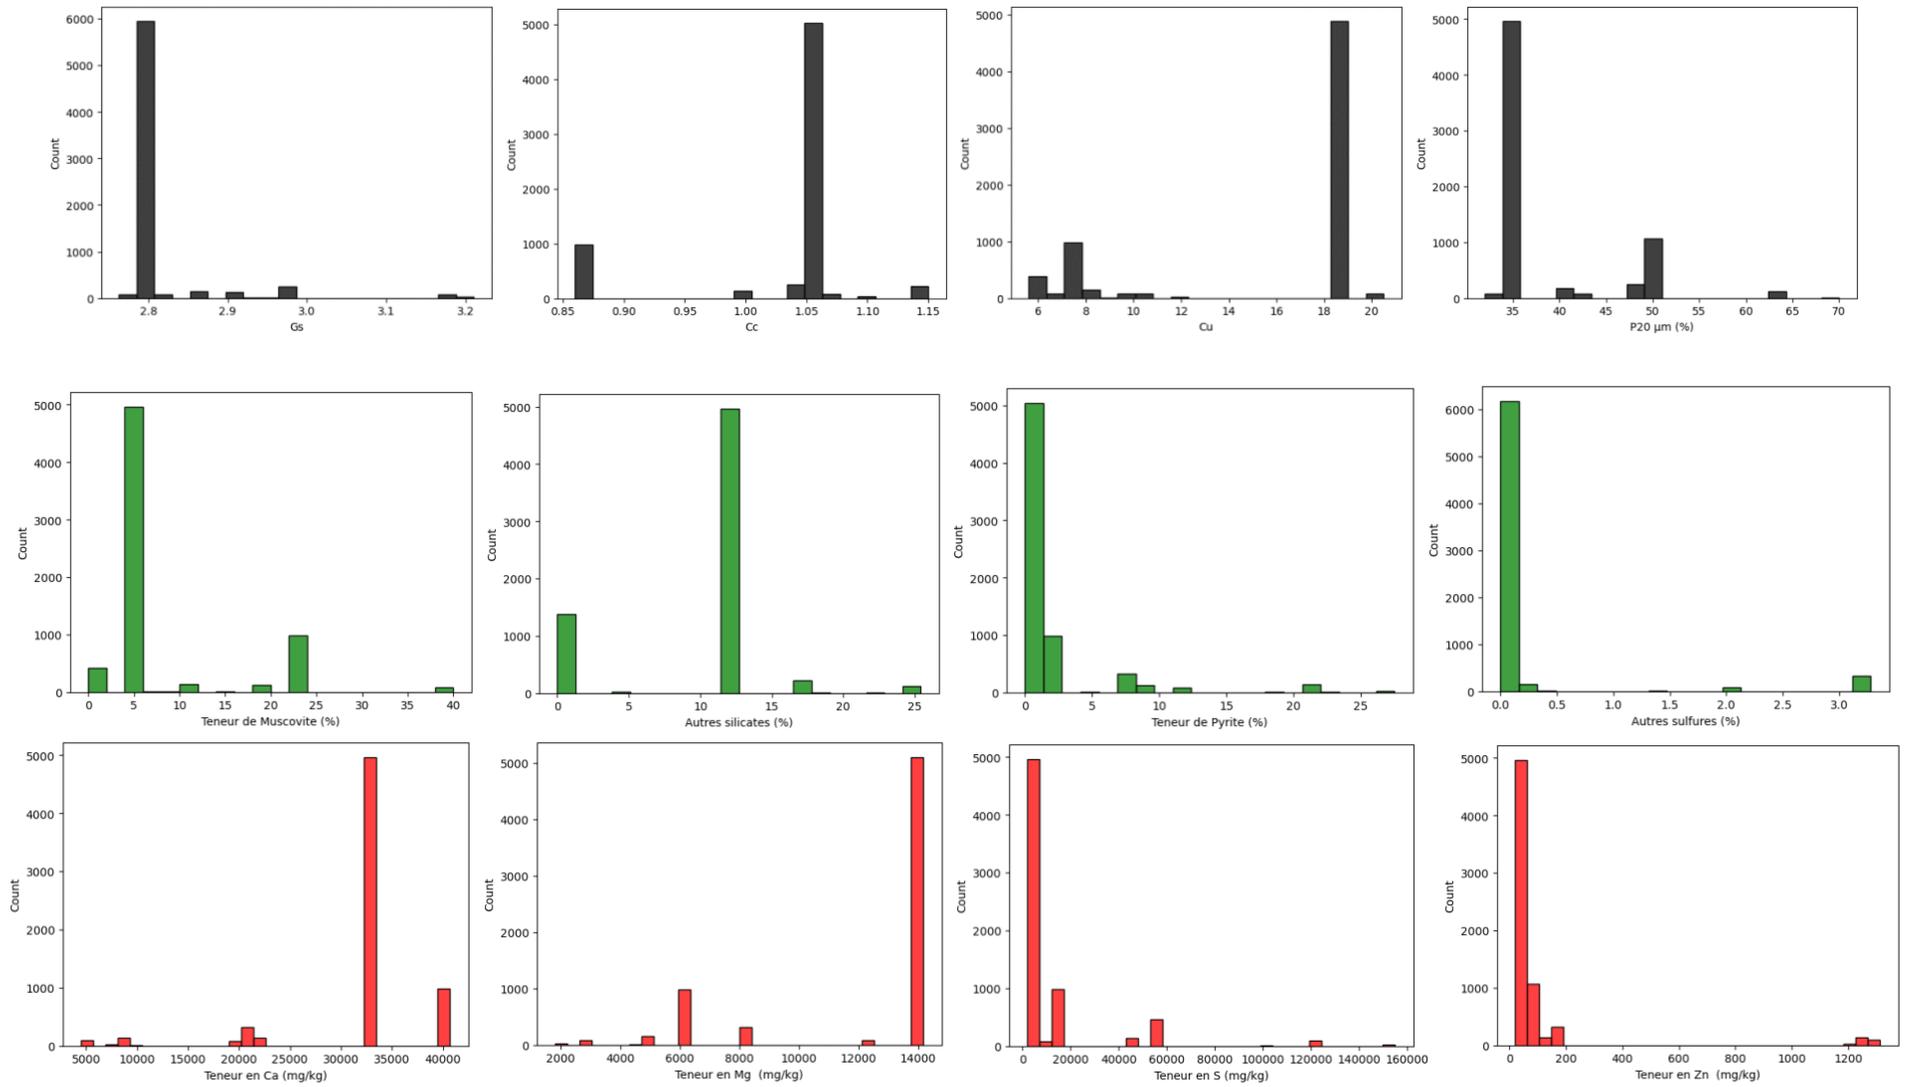


Figure 4-9 Base de données : a) avec valeurs manquantes b) sans valeurs manquantes



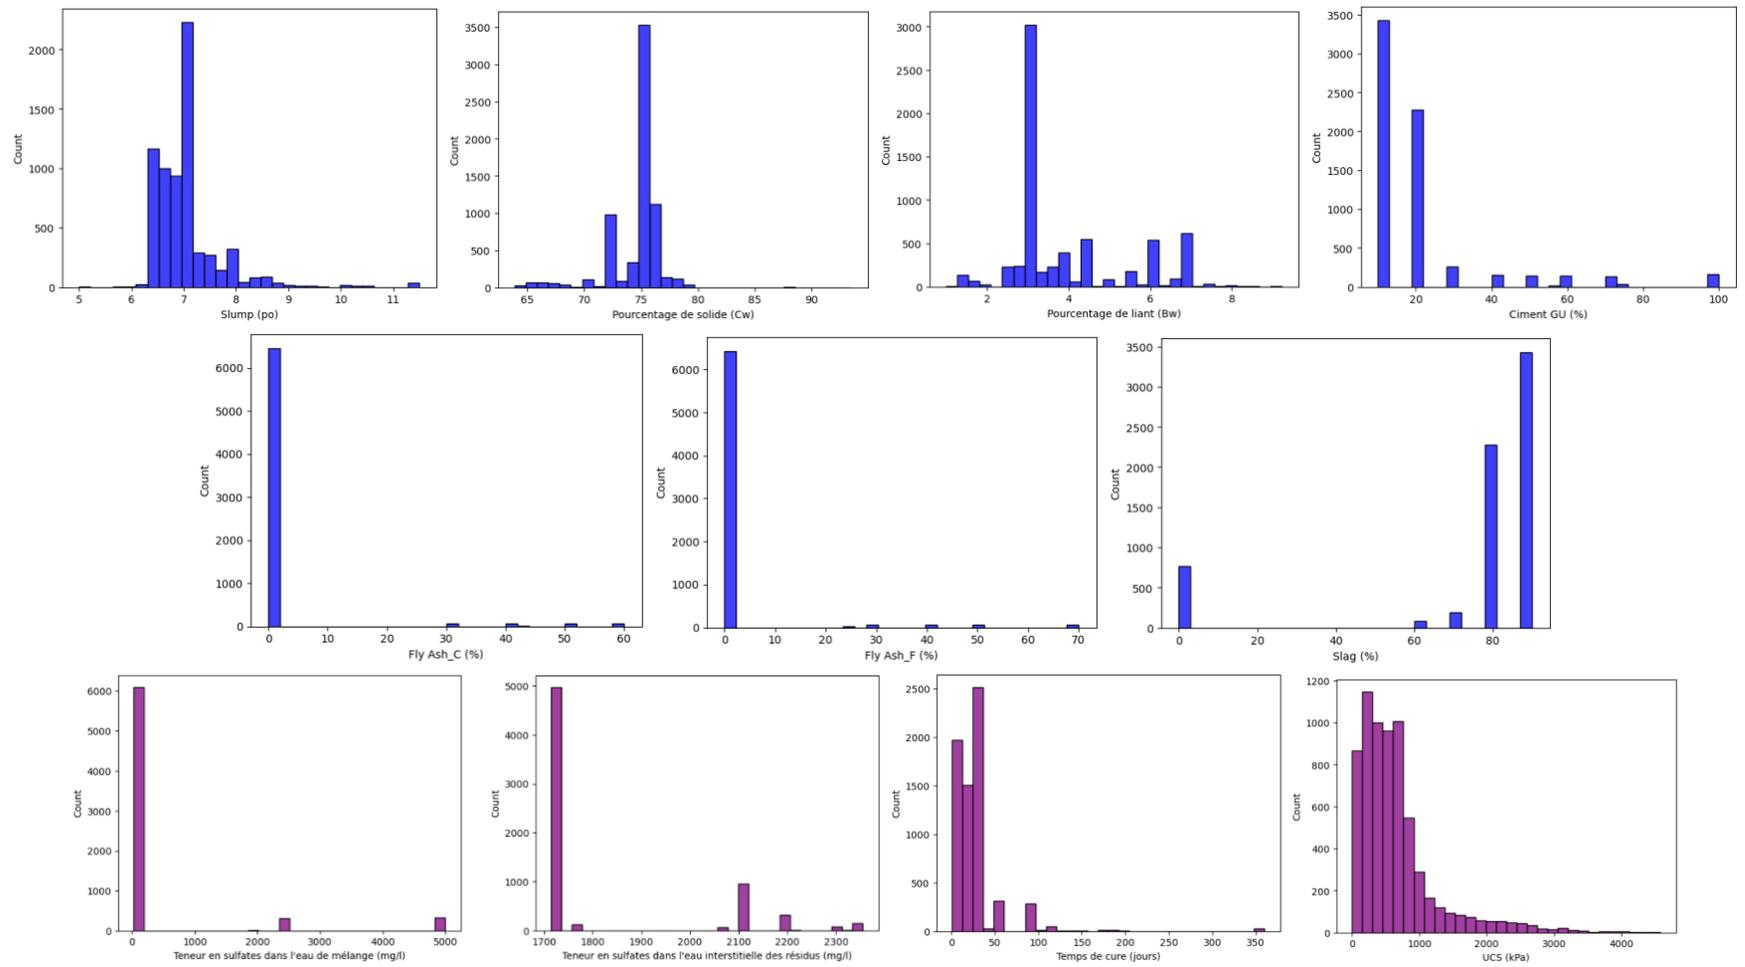


Figure 4-10 Distribution des variables

Pour bien comprendre ces distributions, on a décrit statistiquement les données dans le Tableau 4-3. Il représente la valeur moyenne, l'écart type, les valeurs minimales, les valeurs maximales, les valeurs à 25%, 50% et 75% de toutes les variables. On distingue une grande différence de valeur entre les variables, par exemple l'écart type de G_s égale à 0.06 et celui de teneur en soufre égale à 21 509.66. Cette différence de valeurs rend l'apprentissage des modèles très complexe et même empêche leurs convergences. De plus, la courbe de densité de probabilité (Figure 4-11) montre une distribution quelconque de la variable UCS, ce qui résulte par la suite des valeurs aberrantes qui sont représentées par des points dans la Figure 4-12. Ces valeurs ont un effet néfaste sur les performances des modèles de prédiction (Nyitrai and Virág, 2019). C'est la raison pour laquelle une normalisation des données sera suivie pour minimiser leurs effets (John, 1995; Osborne and Overbay, 2004).

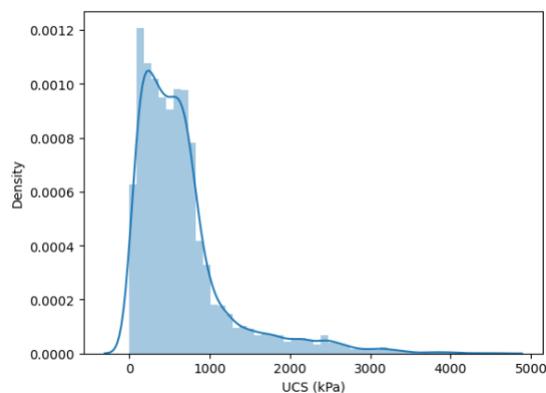


Figure 4-11 Densité de probabilité de l'UCS

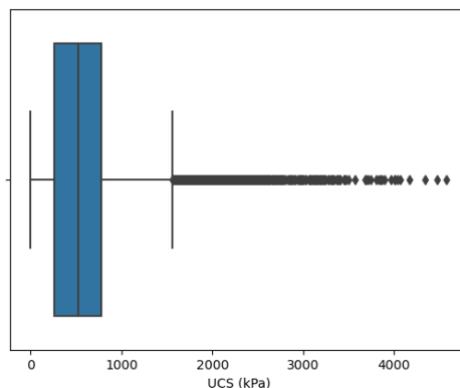


Figure 4-12 Boîte à moustaches de l'UCS

Tableau 4-3 Description statistique des variables

	Moyenne	Écart-type	Min.	Max.	Valeur à 25 %	Valeur à 50 %	Valeur à 75 %
Gs	2.82	0.06	2.76	3.21	2.79	2.79	2.8
Cc	1.02	0.07	0.86	1.15	1.055	1.055	1.055
Cu	15.59	4.93	5.6	20.50	10.68	18.5	18.5
P₂₀ µm (%)	38.61	6.86	32	70	35	35	40
% Muscovite	7.66	7.65	0	40	4.38	4.38	4.38
% Autres silicates	9.71	5.39	0	25.4	11.65	11.65	11.65
% Pyrite	1.66	4.12	0	27.5	0	0	2.68
% Autres sulfures	0.19	0.72	0	3.28	0	0	0
Quantité de Ca (mg/kg)	31868.88	6743.47	4521	40696	32620	32620	32620
Quantité de Mg (mg/kg)	12012.92	3258.87	1823	14180	13780	13780	13780
Quantité de S (mg/kg)	10963.13	21509.66	2050	155000.00	2050	2050	16237
Quantité de Zn (mg/kg)	88.36	241.31	20	1313	20	20	89
Slump (po)	7.02	0.63	5	11.5	6	7	7
Pourcentage de solide C_w (%)	74.57	2.31	63.9	93.45	74.6	75.3	75.7
Ciment GU (%)	20.51	18.39	10	100	10	10	20
Fly Ash_C (%)	1.92	9.35	0	60	0	0	0
Fly Ash_F (%)	2.09	10.02	0	70	0	0	0
Slag (%)	75.47	27.64	0	90	80	90	90
Pourcentage de liant B_w(%)	3.96	1.5	1	9.22	3	3.1	4.5
Teneur en sulfates dans l'eau de mélange (mg/l)	498.92	1135.93	25	5000	171	171	171
Teneur en sulfates dans l'eau interstitielle des résidus (mg/l)	1825.67	196.45	1715	2355	1715	1715	1715
Temps de cure (jours)	26.10	32.88	1	360	7	21	28
UCS (kPa)	649.94	594.18	0	4581	259.77	519.90	780.00

4.3.1.2 Corrélations entre les variables

Il est primordial d'étudier les corrélations entre les données afin de bien comprendre la base de données et de quantifier les relations entre ces dernières et plus principalement la relation entre toutes les variables d'entrées et l'UCS. La Figure 4-13 représente l'ensemble des données sur un plan bidimensionnel, qui décrit la relation entre eux. Les nuages des points de toutes ces données dans le plan cartésien ne montrent pas une relation linéaire claire. Cependant le trait discontinu en rouge représente une estimation de régression entre ces variables. Ces tendances sont en accord à ceux obtenus dans la section 4.2.3.

De plus, comme il est mentionné ci-dessus, les variables ont une distribution non gaussienne, ce qui nous permet de choisir la méthode de corrélation de rang non paramétrique « Spearman » pour étudier les relations des variables. Dans le cas où les variables forment un nuage de points monotone et ayant des distributions normales, le coefficient de corrélation de Pearson sera utile (Xiao et al., 2016). La Figure 4-14 représente une matrice diagonale symétrique de corrélation entre les variables deux à deux. Les forts coefficients de corrélations positives et négatives sont représentés respectivement en couleur rouge et bleu. On s'intéresse plus précisément aux relations qui relient les variables d'entrées à l'UCS (dernières colonnes). Les tendances positives illustrées dans la Figure 4-13 sont traduites par des coefficients positifs dans la matrice. Cependant les tendances négatives sont traduites par des coefficients de corrélations négatives. On peut distinguer également l'effet de type de ciment sur l'UCS, dont l'augmentation de taux de substitution de ciment par le Slag améliore l'UCS. Au contraire, un agent liant possédant un taux de ciment Portland GU élevée dégrade la résistance. En outre, la teneur en sulfates, soit dans l'eau de mélange, soit dans l'eau interstitielle des résidus, défavorise le développement de la résistance. Des faibles coefficients de corrélations entre la chimie des résidus et l'UCS dû au besoin de diversité de ces données.

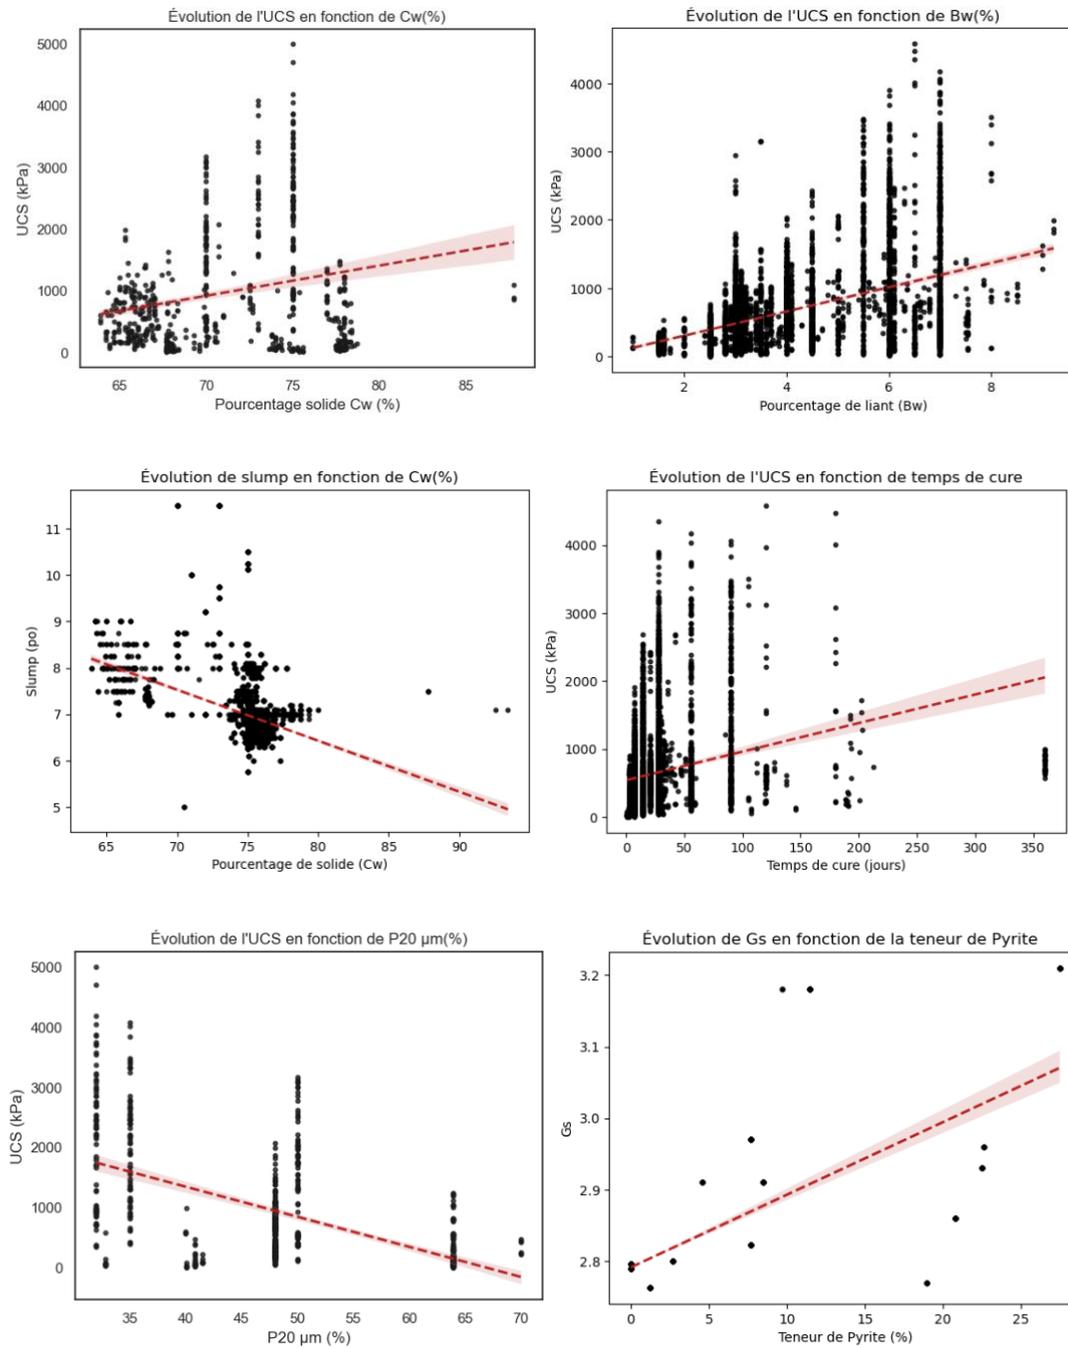


Figure 4-13 Tendances entre les variables

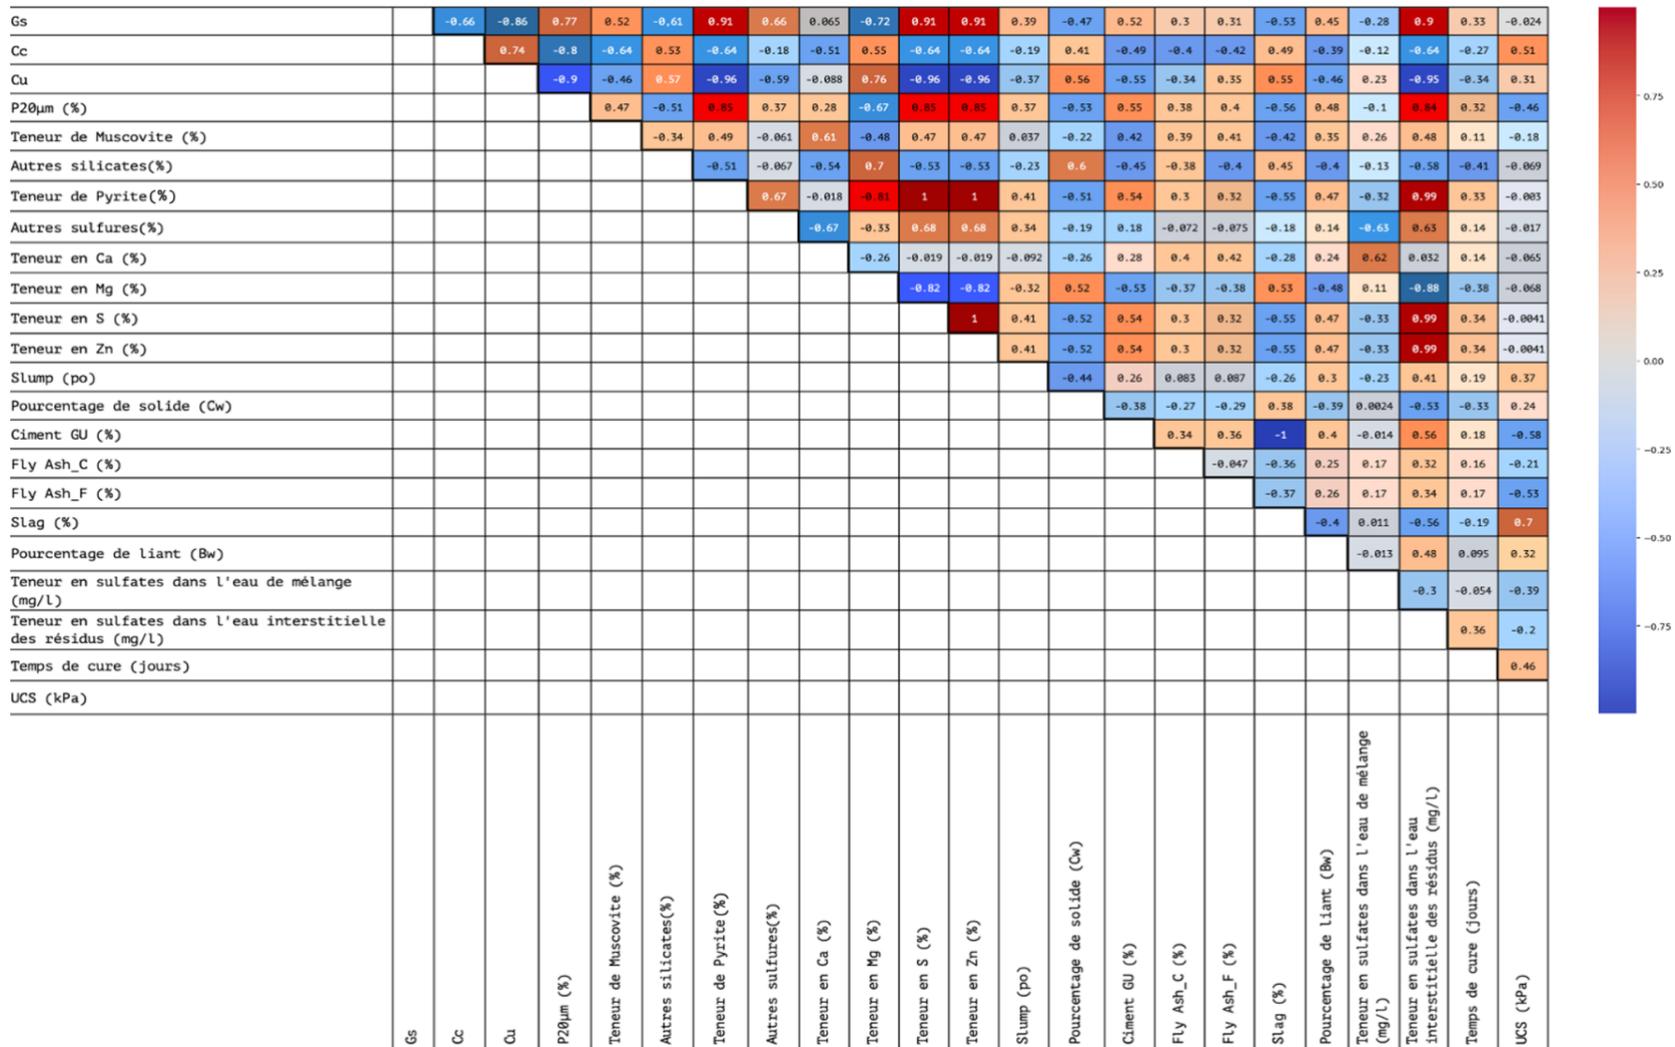


Figure 4-14 Matrice de corrélations entre les variables

4.3.1.3 Normalisation des variables

Afin de minimiser les valeurs aberrantes et de favoriser l'apprentissage des algorithmes, on a mis toutes les données dans une échelle similaire, en utilisant la méthode « *Quantile Transformer* » décrite dans la section 3.4.2 du chapitre 3 de façon que les variables suivent une distribution normale (Figure 4-15) et de minimiser les valeurs aberrantes (Figure 4-16).

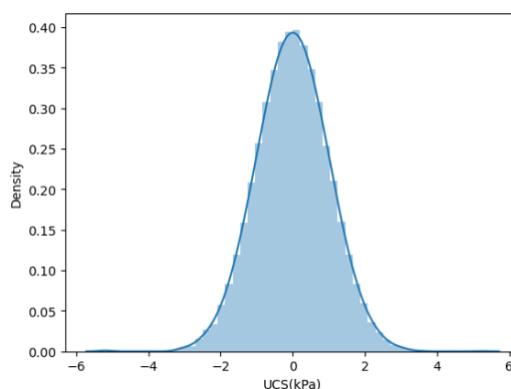


Figure 4-15 Densité de probabilité de l'UCS après normalisation

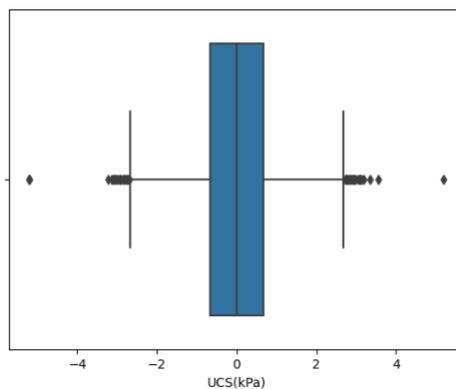


Figure 4-16 Boîte à moustaches de l'UCS après normalisation

4.3.2 Réglage des hyperparamètres des modèles

Dans l'apprentissage automatique, on trouve deux grandes catégories des modèles selon le type de leurs paramètres : des modèles paramétriques et des modèles non paramétriques.

Dans le premier cas, les paramètres du modèle sont définis avant l'apprentissage, ce sont des paramètres internes du modèle. Dans le second cas, les paramètres du modèle contrôlent le

processus de son apprentissage. Ce sont des paramètres externes et qui sont ajustables; on parle donc ici des hyperparamètres du modèle.

Dans notre cas d'étude, nos modèles sont des modèles non paramétriques et qui présentent divers paramètres. Le choix manuel de valeur de chaque paramètre semble compliqué, en plus savoir quelle est la meilleure combinaison de tous les paramètres qui donne un bon score au modèle c'est encore plus dur. C'est pour cette raison qu'il existe des processus qui permettent d'optimiser (ou de chercher) ces hyperparamètres. Cette étape d'optimisation est indispensable lorsqu'on développe des modèles de ML et DNN.

Les méthodes les plus connues pour la recherche des hyperparamètres optimaux sont la recherche par grille « *GridSearch* » et la recherche aléatoire « *RandomSearch* ».

- La recherche par grille « *GridSearch* »

Cette méthode consiste tout d'abord à créer une grille (une liste) des valeurs de tous les paramètres du modèle qu'on voudra essayer. Ensuite, entraîner l'algorithme plusieurs fois en utilisant toutes les combinaisons possibles de ces paramètres. Après, pour évaluer la performance du modèle sur les données du test, on lui affecte un score pour chaque combinaison des paramètres (Lerman, 1980). Finalement, cette méthode nous renvoie la combinaison des hyperparamètres optimaux qui correspond au score le plus élevé.

- La recherche aléatoire « *RandomSearch* »

Le processus de cette méthode est similaire à celle du « *GridSearch* », mais au lieu de tester toutes les combinaisons possibles des hyperparamètres, il teste juste des combinaisons aléatoires. Lorsqu'on développe des modèles avec nombreux paramètres, le test sera très lent et inefficace. C'est la raison pour laquelle cette méthode est robuste (Andradóttir, 2006; Zabinsky, 2009).

Dans la présente étude, la méthode de recherche aléatoire a été utilisée. Le Tableau 4-4 représente les hyperparamètres optimaux de chaque modèle, leurs définitions et leurs valeurs optimales.

Tableau 4-4 Hyperparamètres optimaux des modèles

Modèle	Hyperparamètres	Définition	Valeurs
RF	<code>n_estimators</code>	Le nombre d'arbres totales	1000
	<code>min_samples_split</code>	Le nombre minimum d'échantillons pour diviser un nœud interne	2
	<code>max_depth</code>	La profondeur maximale de l'arbre	15
GBR	<code>learning_rate</code>	Pas d'apprentissage	0.2867
	<code>max_depth</code>	La profondeur maximale de l'arbre	4
	<code>min_samples_split</code>	Le nombre minimum d'échantillons pour diviser un nœud interne	2
	<code>n_estimators</code>	Le nombre d'arbres totales	895
	<code>subsample</code>	Ratio de sous-échantillonnage des données d'entraînement.	0.5
XGBR	<code>n_estimators</code>	Le nombre d'arbres totales	400
	<code>max_depth</code>	La profondeur maximale de l'arbre	6
	<code>learning_rate</code>	Pas d'apprentissage	0.5
	<code>gamma</code>	La réduction minimale des pertes requise pour effectuer un fractionnement.	0

En ce qui concerne le DNN, après avoir propagé toutes les données dans le réseau de neurones, il est nécessaire de faire la rétropropagation vers l'arrière afin d'ajuster les paramètres et de minimiser l'erreur pour améliorer la précision de la prédiction. L'ajustement manuel d'un DNN avec des millions des paramètres, c'est une tâche inexécutable. C'est la raison pour laquelle nombreux algorithmes d'optimisations (ou optimiseurs) basés sur la descente de gradient sont intégrés dans l'API Keras (Tableau 4-5) seront utilisés dans cette étude. Mais, avant tout il faut bien choisir cet algorithme d'optimisation. Cependant, il n'y a pas de règle bien définie pour ce choix, mais certains algorithmes ne fonctionnent pas pour de grandes bases de données (milliers des données) comme l'algorithme de la propagation de l'erreur moyenne quadratique (*Root Mean Square propagation - RMS Prop*), d'autres algorithmes prennent beaucoup de temps pour converger comme l'algorithme de la descente de gradient stochastique (*Stochastic Gradient Descent - SGD*). Donc, la meilleure manière de faire, c'est d'essayer différents algorithmes selon la taille de la base de données et d'évaluer leurs performances.

Après plusieurs itérations sur différents algorithmes, le meilleur algorithme qui converge rapidement et qui a donné la meilleure précision, c'est l'algorithme de l'estimation adaptative du moment (*Adaptive Moment Estimation* - Adam). Cet algorithme a été sélectionné comme meilleur optimiseur grâce à son ajustement dynamique et adaptatif du taux d'apprentissage en fonction des poids des neurones et d'ailleurs c'est l'algorithme le plus utilisée en *Deep Learning*.

Tableau 4-5 Algorithmes d'optimisation de Keras-TensorFlow

Abréviation d'optimiseur	Nom d'optimiseur dans Keras
Descente de gradient stochastique (<i>Stochastic Gradient Descent</i>)	SGD
Propagation de l'erreur moyenne quadratique (<i>Root Mean Square propagation</i>)	RMSprop
Estimation adaptative du moment (<i>Adaptive Moment Estimation</i>)	Adam
Suivi de leader régularisé (<i>Follow The Regularized Leader</i>)	Ftrl

Bien qu'ils soient fonctionnels pour les plus parts des problèmes de classifications autant que les problèmes de régression, leurs performances dépendent fortement de leur architecture et leur hyperparamètre tels que, le nombre de couches cachées, le nombre des neurones dans chaque couche cachée, ainsi que le type d'optimiseur et son pas d'apprentissage, etc. Il faut noter aussi que pour les réseaux de neurones, le choix manuel de ces hyperparamètres optimaux reste un problème de recherche et il n'y a pas une manière universelle dans le pratique pour les choisir. Au lieu de cela, ils sont souvent déterminés par essais et erreurs.

En revanche, il existe plusieurs algorithmes d'optimisation qui facilitent la recherche des hyperparamètres intégrés dans l'API Keras tel que les algorithmes bayésiens (*BayesianOptimization*), les algorithmes hyperbandes (*Hyperband*) et les algorithmes de recherche aléatoire (*RandomSearch*).

De la même manière avec les algorithmes de ML, la méthode de recherche aléatoire a été utilisée pour déterminer les hyperparamètres du DNN grâce à sa robustesse et sa rapidité de recherche. Le processus de recherche a été suivi par une validation croisée dans le but de valider l'essai sur

l'ensemble de validation; la sélection de la meilleure combinaison correspond à l'erreur quadratique moyenne (MSE) la plus faible obtenue sur l'ensemble de validation.

Les paramètres du DNN qui ont été testés dans cette étude sont définis comme suit:

- Nombre des couches cachées : 1 à 10 couches
- Nombre de neurones dans chaque couche cachée : 20 à 100 avec un pas de 10
- Fonction d'activation dans chaque couche cachée : ReLU, Sigmoid, *tanh*
- Fonction d'optimisation (optimiseur) : Adam, SGD
- Fonction de perte : MSE
- Taux d'apprentissage pour l'optimiseur stochastique : 0.01, 0.001, 0.0001

Dix itérations (essais) sur les données d'apprentissage ont été fixées (max trials = 10), une validation croisée à 10 divisions (10 fold cross validation). En tenant compte du nombre des paramètres mentionnés ci-dessus à tester, on obtient au total 162 000 exécutions ($10 * 9 * 3 * 2 * 1 * 3 * 10 * 10$) pour chercher les hyperparamètres optimaux du DNN. Cela prend beaucoup de temps de calcul pour réussir à sélectionner les hyperparamètres, ce qui justifie le choix la méthode de recherche aléatoire (RandomSearch).

Cet algorithme permet d'avoir des hyperparamètres optimaux avec une MSE sur les données d'apprentissage égale à 0.00749 qui sont les suivants :

- Nombre des couches cachées = 4
 - Première couche cachée possède 60 neurones avec tanh comme fonction d'activation
 - Deuxième couche cachée possède 70 neurones avec relu comme fonction d'activation
 - Troisième couche cachée possède 20 neurones avec relu comme fonction d'activation
 - Quatrième couche cachée possède 20 neurones avec relu comme fonction d'activation

- Pas d'apprentissage = 0.0001
- Optimiseur : Adam
- Fonction de perte : MSE

Le type de couches cachées utilisées dans cette étude, c'est la couche dense (Dense layer). C'est une couche profondément connectée entre sa couche précédente et sa couche suivante; ce type de couche permet de faire le calcul de la propagation vers l'avant qu'on a cité avant.

Vu qu'on a normalisé nos données hors du réseau de neurones, la fonction d'activation de la couche d'entrée est une fonction ReLU et pour la couche de sortie également c'est une fonction ReLU qui renvoie la valeur du neurone (z ou 0), ce qui justifie la sélection de ces deux fonctions par l'algorithme de recherche aléatoire.

Après avoir sélectionné les hyperparamètres du DNN et défini son architecture, on a réentraîné ce réseau sur l'ensemble d'apprentissage 700 fois (epochs = 700) afin de s'assurer un bon apprentissage et de le tester sur l'ensemble de validation.

L'architecture du réseau développé est représentée dans les Figures 4-17 et 4-18 :

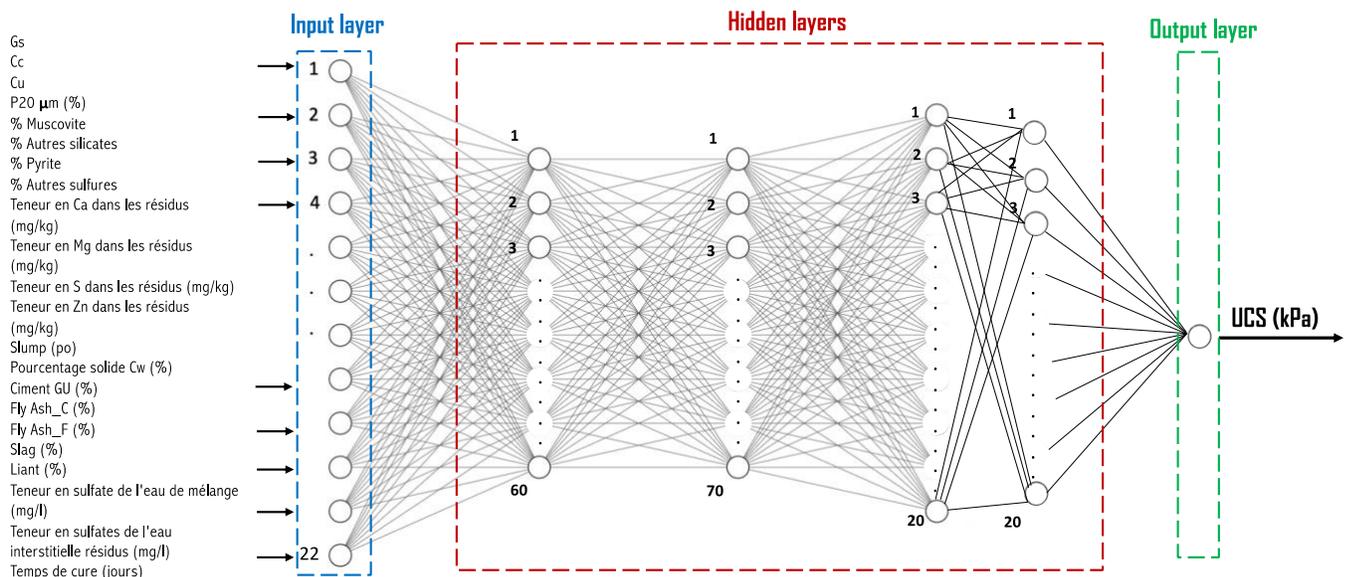


Figure 4-17 Architecture du réseau Deep Neural Network (DNN)

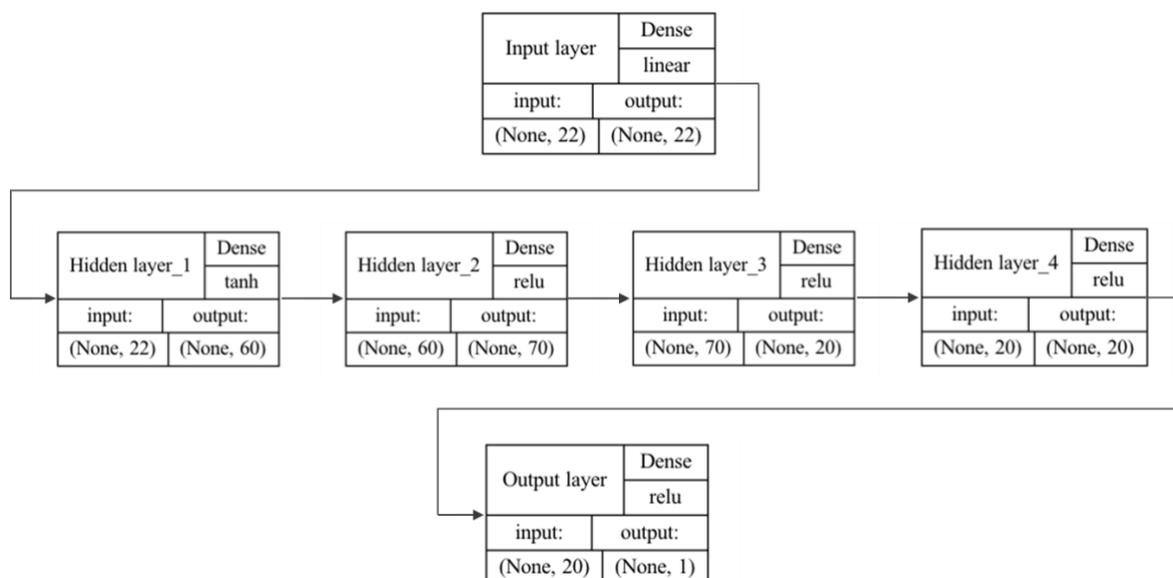


Figure 4-18 Description des couches du DNN

Le nombre des paramètres entraînés et ajustés (w_{ij} , et b_i) à chaque couche cachée du DNN sont définis dans le Tableau 4-6; au total **8 017 paramètres** ont été entraînés dans ce réseau. Tous les paramètres ont été entraînés, ce qui montre un bon ajustement du modèle.

Tableau 4-6 Nombre de paramètres dans chaque couche du DNN

Layer/couche (type)	Output Shape/sortie	Parameters
Input layer (Dense)	(None, 22)	506
Hidden layer 1 (Dense)	(None, 60)	1 380
Hidden layer 2 (Dense)	(None, 70)	4 270
Hidden layer 3 (Dense)	(None, 20)	1 420
Hidden layer 4 (Dense)	(None, 20)	420
Output layer (Dense)	(None, 1)	21
Total parameters: 8017		
Trainable parameters: 8017		
Non-trainable parameters: 0		

4.3.3 Performances des modèles

Afin d'évaluer la qualité des modèles prédictifs développés, on a utilisé des indicateurs de performances statistiques de régression tels que :

Le coefficient de corrélation R, s'exprime par la relation suivante :

$$R = \frac{\sum_{i=1}^N (y_i^* - \bar{y}^*)(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (y_i^* - \bar{y}^*)^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2}} \quad (4-1)$$

Avec y_i , y_i^* représentent respectivement les valeurs réelles et prédites, \bar{y} et \bar{y}^* sont les valeurs moyennes.

Il traduit la qualité de prédiction d'un modèle par la mesure de la relation entre la valeur prédite et la valeur réelle. En effet, le coefficient R prend des valeurs entre 0 et 1. Une valeur proche de 1 se traduit par un bon ajustement du modèle, autrement dit ce modèle est capable de se généraliser pour faire des prédictions avec précision. À l'inverse, une valeur proche de 0 indique un mauvais ajustement et par conséquent une mauvaise qualité de prédiction.

L'erreur moyenne quadratique (*Mean squared error* - MSE) :

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - y_i^*)^2 \quad (4-2)$$

La racine de l'erreur moyenne quadratique (*Root Mean squared error*-RMSE) :

$$RMSE = \sqrt{MSE} \quad (4-3)$$

C'est un indicateur de performance principal pour un modèle prédictif destiné à la résolution de problème de régression. Sur un ensemble des données définies, il mesure la racine de l'écart moyen entre les valeurs réelles et les valeurs prédites par les modèles. Il estime la capacité du modèle prédictif à prévoir la valeur de la variable cible.

Comme son l'indique, l'erreur moyenne quadratique (MSE) mesure l'erreur de prédiction au carré produite par le modèle, ce qui donne une erreur d'unité au carré de la variable cible. Tandis que sa racine (RMSE) mesure l'erreur dans la même unité que la variable cible. C'est pour cela que le MSE est très souvent pénalise les erreurs d'une façon sévère.

L'erreur moyenne absolue (*Mean absolute error* - MAE) :

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - y_i^*| \quad (4-4)$$

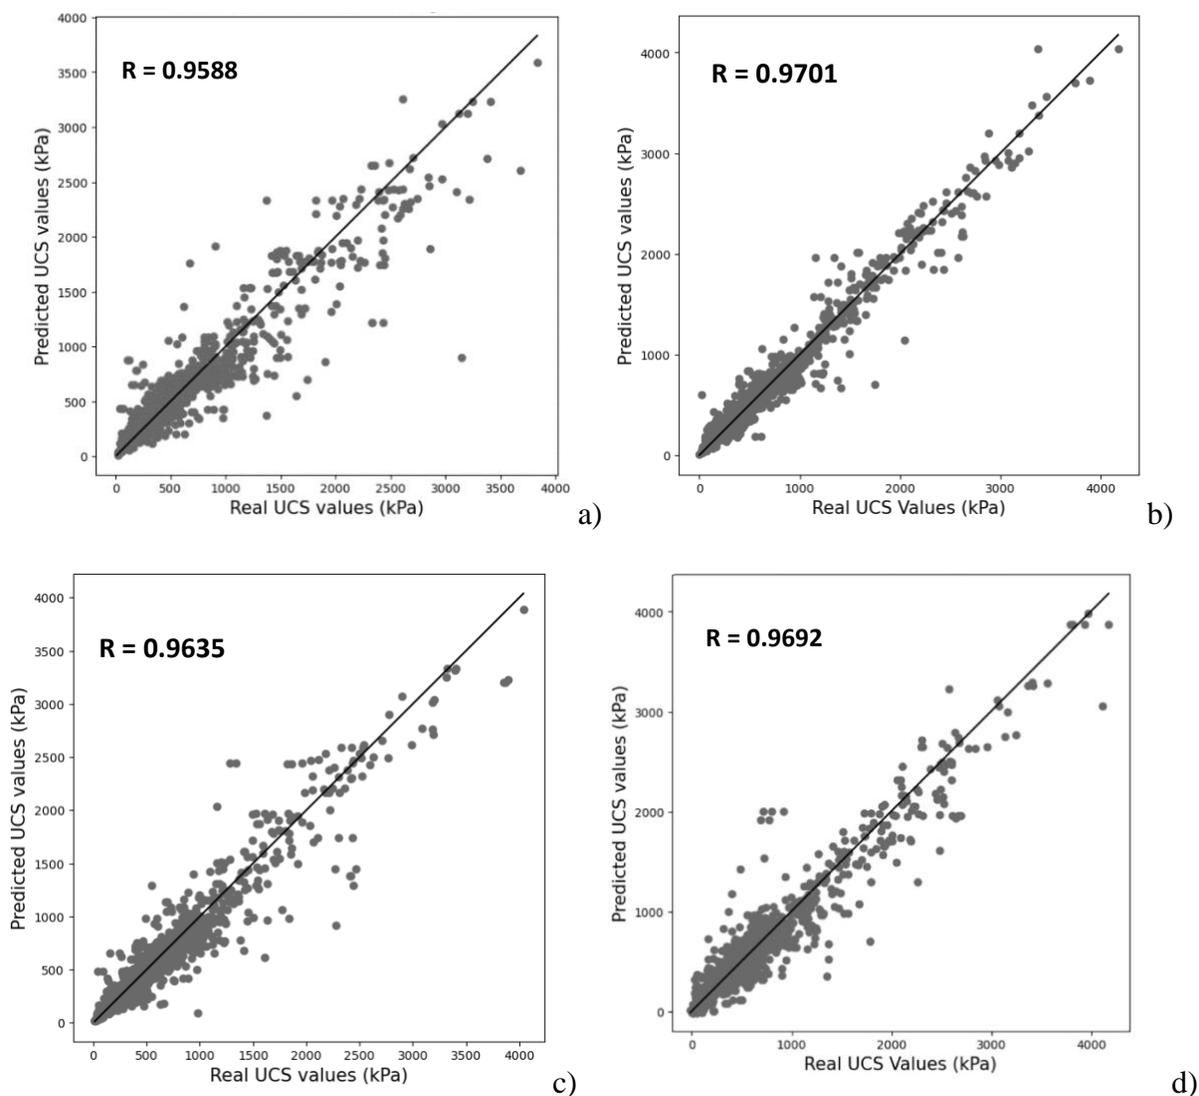


Figure 4-19 Comparaison sur la pente 1 :1 des prédictions des modèles; a) RF, b) GBR, c) XGBR, d) DNN

Les courbes ci-dessus comparent les valeurs prédites par chaque modèle et les valeurs réelles de l'UCS de l'ensemble de test à la droite idéale de pente 1:1 (valeurs prédites = valeurs réelles). Il est évident que les modèles sont capables de se généraliser sur de nouvelles données lorsqu'on voit un bon ajustement sur la pente. En comparant ces modèles, le *GradientBoostingRegressor* présente le meilleur ajustement. Il a donné le meilleur coefficient de corrélation R qui est égale à 0.9701 par rapport les autres modèles : RF, XGBR et DNN qui ont donné des coefficients respectivement égaux à 0.9588, 0.9635, 0.9692.

Afin d'approfondir plus l'évaluation de nos modèles, il est nécessaire d'interpréter l'évolution de leurs apprentissages. C'est pour cela, qu'on les a réentraînées et cette fois-ci on a appliqué la

méthode de validation croisée de k fractionnements sur la base de données (*k-fold Cross Validation*). En effet, cette méthode consiste à diviser aléatoirement l'ensemble de données d'apprentissages en k sous-ensembles, dont $k-1$ ensembles sont dédiés à l'entraînement des modèles (training set) et un seul ensemble pour la validation (validation set) comme le montre la Figure 4-20. Autrement dit, à chaque fois le modèle s'entraîne sur l'ensemble d'apprentissage et s'évalue sur l'ensemble de test en lui donnant un score. Ce processus de validation croisée sera répété k fois, et dans cette étude, k a été fixé à 5. Le grand avantage de cette méthode, c'est qu'elle permet au modèle de s'entraîner plusieurs fois, ce qui lui permet d'améliorer son score de prédiction. Elle évite également le surapprentissage des modèles.

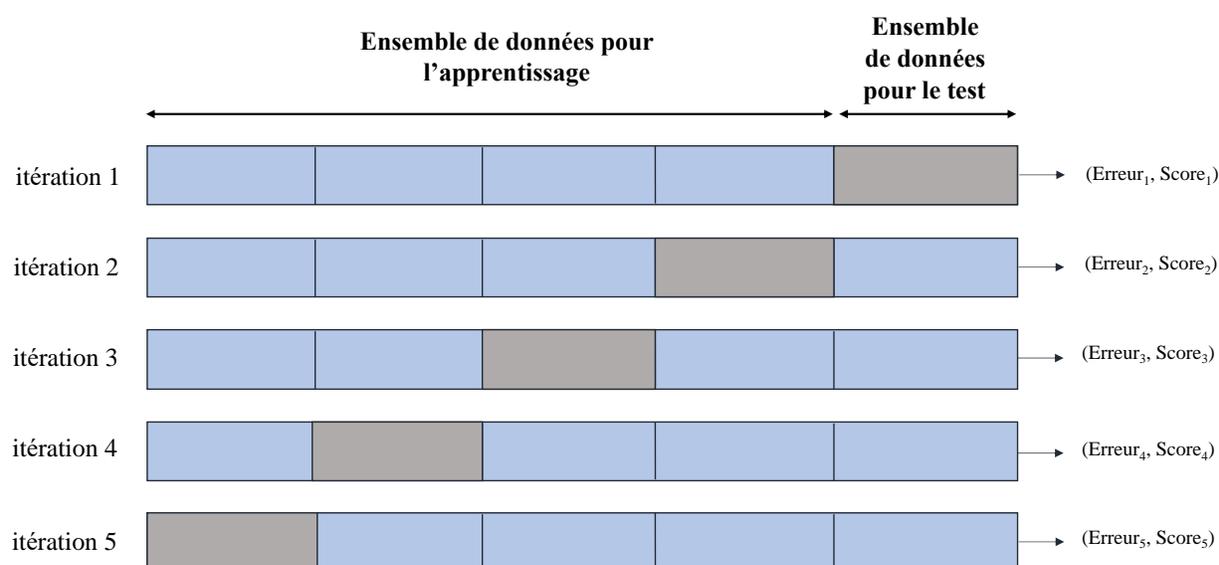


Figure 4-20 Schéma du processus de validation croisée

La Figure 4-21 nous renseigne sur la qualité d'apprentissage de chaque modèle en fonction de la quantité des données qu'il reçoit. En effet, plus le modèle dispose des données de qualité pour s'entraîner, meilleur sera sa performance. Les courbes en bleues montrent que les modèles ont bien appris sur les données d'apprentissage (training set) avec une légère diminution du score lorsque la quantité des données augmentent à cause de la complexité de l'apprentissage lors de la réception d'une quantité énorme d'informations. Ils ont également enregistré de bons scores de prédiction de 0.92, 0.96 et 0.97 respectivement pour les modèles RF, GBR et XGBR; ils ont d'ailleurs presque le même comportement lors de l'apprentissage. Les courbes vertes nous affirment que les modèles sont capables de se généraliser sur de nouvelles données dû au fait que le score augmente avec la

progression d'apprentissage. Cependant, les modèles commencent à se stabiliser, mais ils n'ont pas atteint leurs limites de stabilité, ceci s'explique par un léger manque de données. En revanche, ils ont enregistré de bons scores de prédiction sur les données de validation de 0.876, 0.92 et 0.91 respectivement pour les modèles RF, GBR et XGBR. Le faible écart entre le score de prédiction sur les données d'apprentissage et celui sur les données de validation, la convergence de ces deux scores vers un point de stabilité nous confirme un bon ajustement de ces modèles et qu'ils sont très loin d'être en surajustement (*overfitting*).

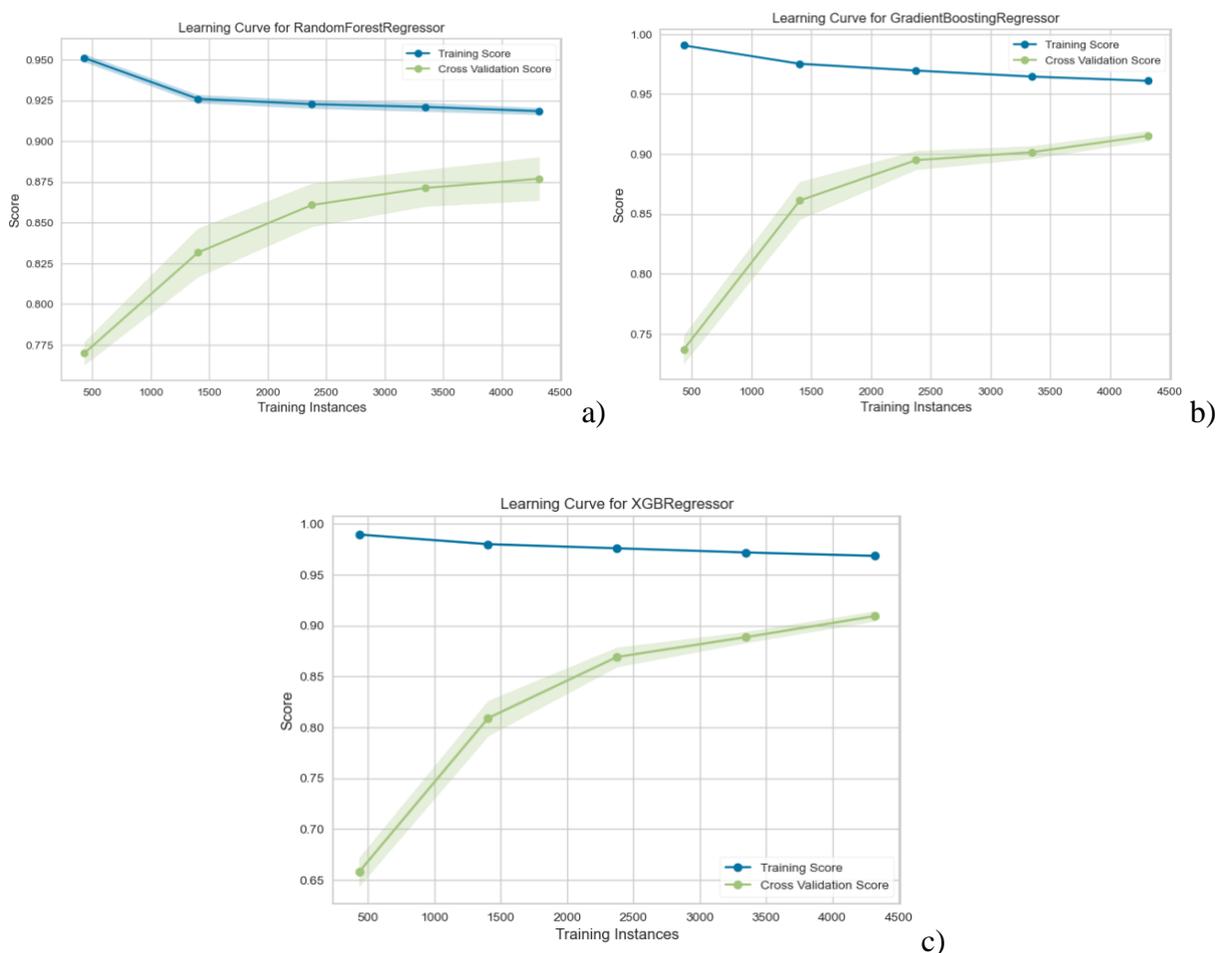


Figure 4-21 Courbe d'apprentissage des modèles : a) RF, b) GBR, c) XGBR

Pour évaluer le réseau de neurones profond (DNN), on a suivi l'évolution de sa fonction de perte (l'erreur moyenne quadratique ou encore le *Mean Squared Error* - MSE) ainsi que sa racine (RMSE). Les Figures 4-22 et 4-23 montrent qu'en cours de son apprentissage, l'erreur quadratique moyenne ainsi que sa racine carrée diminue au cours de nombres d'itérations, ce qui est équivalent

aux données d'apprentissages qu'ils reçoivent et après un certain nombre d'itérations l'erreur se stabilise non seulement pour les données d'apprentissage, mais aussi pour les données de validation. N'oublions pas également que les erreurs sur les données d'apprentissage sont toujours plus faibles que celle sur les données de validation avec un écart faible entre ces deux valeurs, ce qui justifie un bon apprentissage du DNN et l'absence du phénomène de surajustement (*overfitting*) ainsi que le sous-ajustement (*under-fitting*).

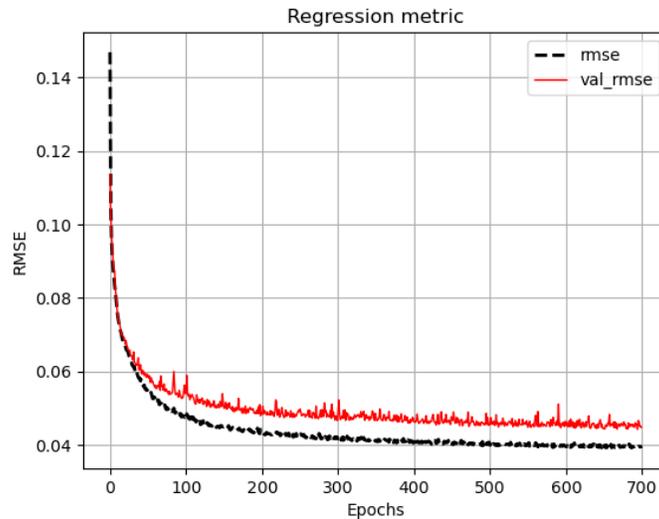


Figure 4-22 Évolution de la métrique du DNN (RMSE) en fonction de nombre d'itérations

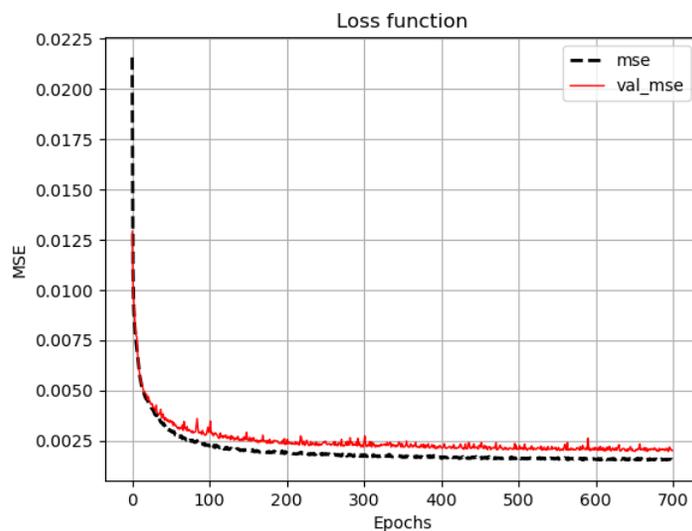


Figure 4-23 Évolution de la fonction perte du DNN (MSE) en fonction de nombre d'itérations

Une autre évaluation des performances des modèles est représentée dans la Figure 4-24, dont une comparaison sur 40 échantillons entre les valeurs prédites par les modèles et celles réelles (valeurs dans la base de données) est bien illustrée. Il est clair qu'il y a une légère différence au niveau de prédiction, mais elle reste faible par rapport d'autres modèles d'apprentissage illustré dans le Tableau 4-8.

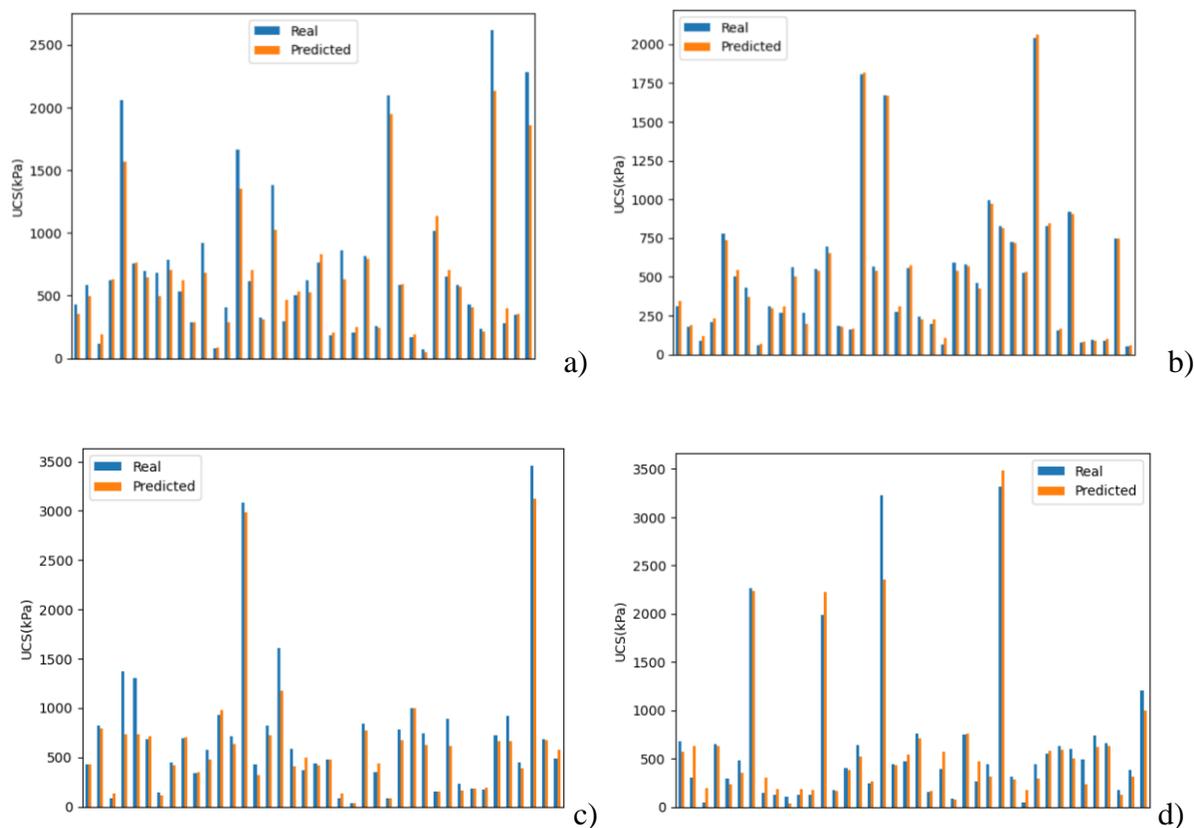


Figure 4-24 Comparaison des valeurs de l'UCS dans l'ensemble de données du test et celles prédites par les modèles; a) RF, b) GBR, c) XGBR, d) DNN

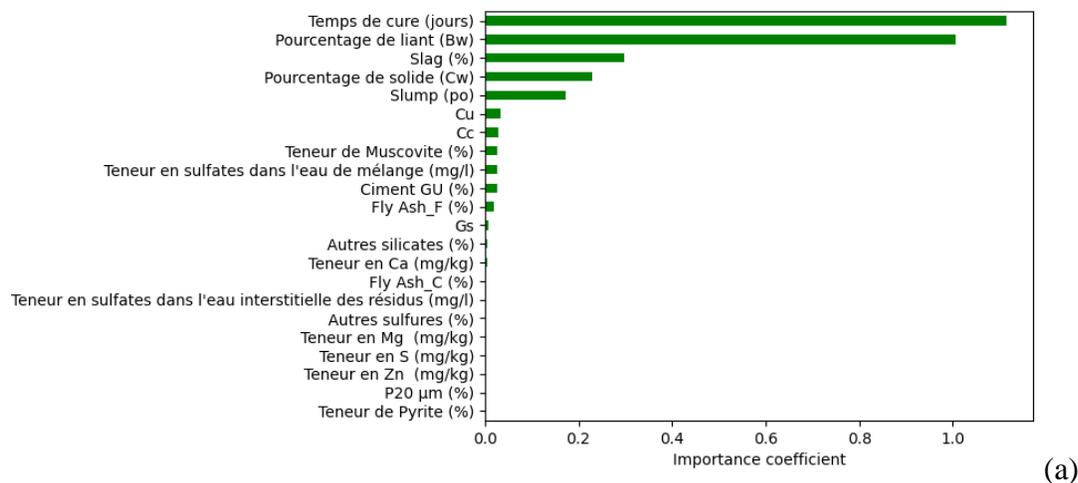
On peut conclure à ce stade que l'algorithme de GBR représente les meilleures performances au niveau de prédiction. Ceci explique par sa théorie ensembliste en série « *Boosting* » qui se repose sur l'amélioration du processus d'apprentissage au fur et à mesure (minimiser l'erreur de prédiction d'arbre après arbre) à l'aide de l'algorithme de la descente de gradient et par conséquent l'amélioration de son aptitude à se généraliser. Cependant, le RF qui est basé sur la théorie ensembliste en parallèle « *Baagging* » a enregistré le plus faible de prédiction. Malgré la robustesse de XGBR au niveau d'entraînement, le GBR était plus performant. Ceci s'explique par sa complexité au niveau de calcul du gradient (second ordre) où il peut se perdre lors de son

apprentissage, ce qui le rend incapable de bien s'ajuster sur les données d'entraînement. Leurs paramètres aussi affectent sa performance, un faible pas d'apprentissage ou un nombre élevé des arbres empêche sa convergence. Il est probable aussi qu'un nombre élevé des échantillons beugue son apprentissage.

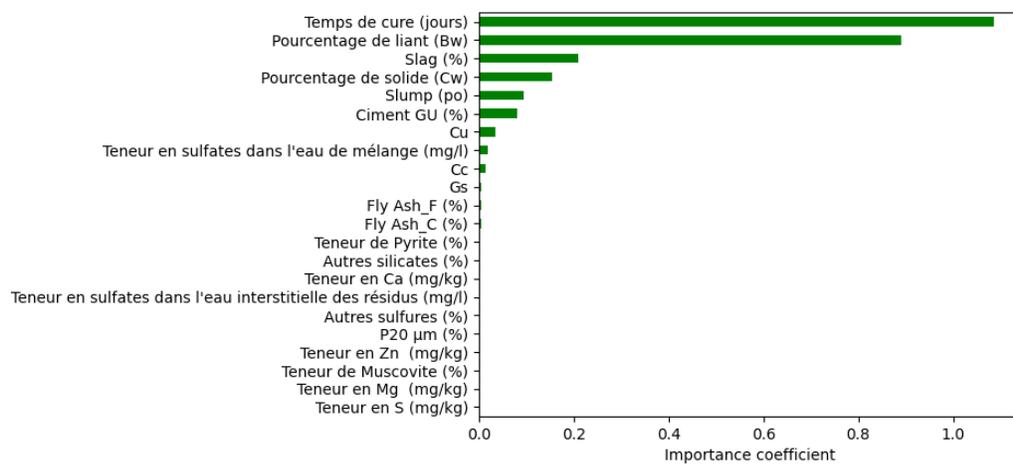
La faible performance du DNN par rapport le GBR est dû aux faibles données d'apprentissage pour un modèle de DL. Il faut noter que pour avoir un réseau de neurones artificiels performant, il faut le fournir à une grande base de données (des milliers) pour son apprentissage.

Une autre manière de comparer les modèles est la façon dont ils voient les données d'entrées (ou les caractéristiques). Les histogrammes de la Figure 4-25 montrent le score d'importance de chaque entrée (*features*) associé à chaque modèle lors de son apprentissage pour prédire la variable cible. Un score très élevé d'une caractéristique se traduit par un effet important de cette dernière sur le modèle prédictif. En outre, le score d'importance d'une telle variable dépend fortement des données qu'elles contiennent, par exemple si une variable présente un peu de diversité dans ses valeurs, donc automatiquement elle ne changera rien au niveau d'apprentissage du modèle et de cette manière, il la voit comme une constante et par conséquent cette variable ne présentera pas un score d'importance élevé. Le GBR a considéré 11 variables importantes lors de son apprentissage, ce qui justifie encore sa robustesse par rapport le XGBR et RF qui ont considéré respectivement 9 et 7 variables importantes. Même si certaines variables (C_u , C_c , teneur en muscovite) ne présentent pas assez de diversité dans ses valeurs, le GBR les voit comme des variables importantes. Il a considéré également le temps de cure, le pourcentage de liant, le pourcentage de Slag, le pourcentage de solides et le *slump*, soit les variables qui ont l'effet le plus marqué sur l'UCS (ce qui est attendu). Le XGBR a un comportement d'apprentissage similaire à GBR, mais un peu plus faible, en revanche le RF souffre lors de son apprentissage le fait qu'il se base sur une minorité des données pour s'entraîner.

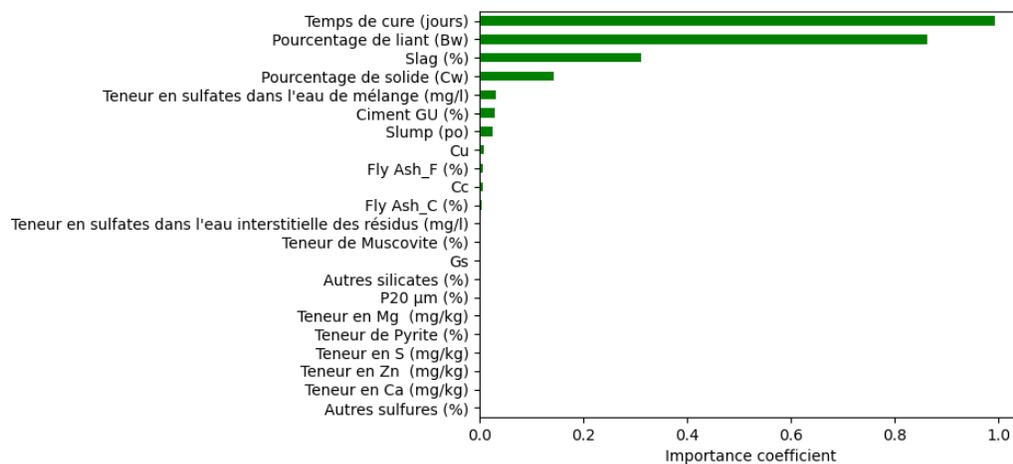
Toutefois, on ne s'arrêtera pas à ce stade pour évaluer les modèles, au contraire on va plus loin pour l'évaluer à l'échelle de laboratoire.



(a)



(b)



(c)

Figure 4-25 Importance des variables sélectionnées par les modèles : (a) GBR, (b) XGBR, (c) RF

4.3.4 Validation de la prédiction

Afin de valider les modèles, huit formulations de RPC ont été réalisées au laboratoire. Ces recettes ne font pas partie de la base de données. Le but, c'est de fournir aux modèles de nouvelles données qu'ils n'ont jamais vues avant afin de faire des prédictions des UCS correspondantes à ces formulations.

La Figure 4-26 représente une comparaison des prédictions de l'UCS obtenues par les modèles et des UCS expérimentales. Il est évident que les UCS prédites par le GBR sont très proches des valeurs réelles, il représente la plus faible erreur moyenne absolue de 21.8 kPa. On trouve en deuxième ordre de classement le réseau de DNN, mais il est majoritairement en surestimation de l'UCS avec une erreur moyenne absolue de 110.25 kPa. En troisième position, le XGBR qui est majoritairement en sous-estimation avec une erreur moyenne absolue de 227.10 kPa et en dernière position on retrouve le RF qui est totalement en sous-estimation avec une erreur moyenne absolue de 254.88 kPa. On peut voir très clairement dans la Figure 4-27 l'erreur de prédiction de chaque modèle pour les huit formulations. Les erreurs de prédiction négatives montrent la sous-estimation de l'UCS, tandis que les erreurs positives montrent la surestimation.

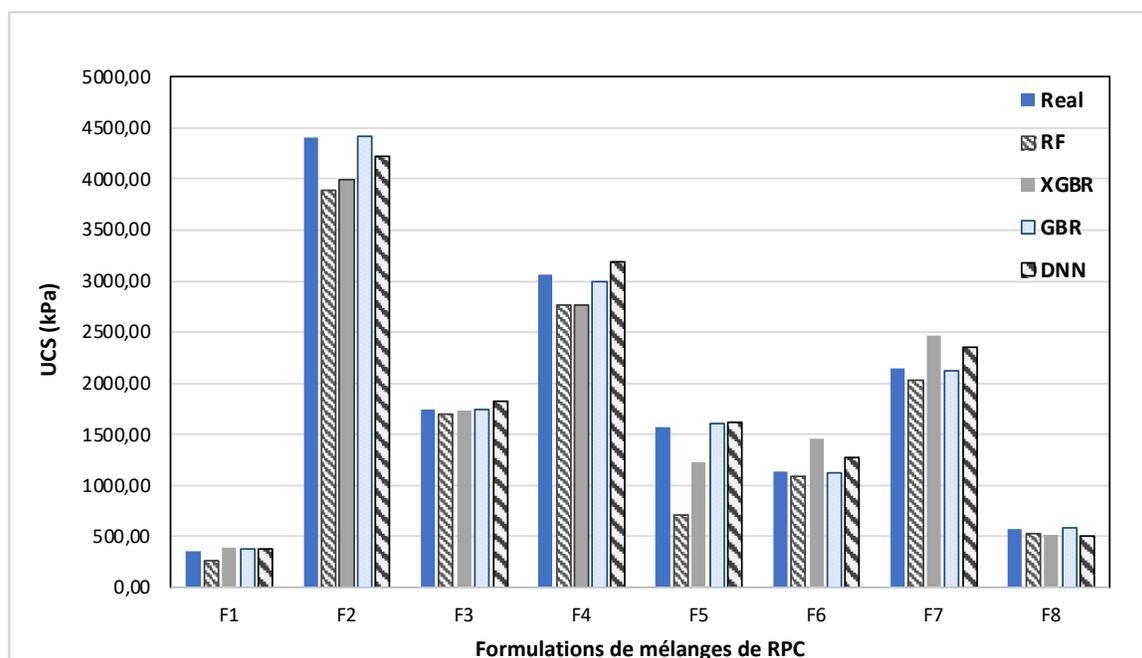


Figure 4-26 Comparaison des UCS prédites par les modèles et celles obtenues expérimentalement

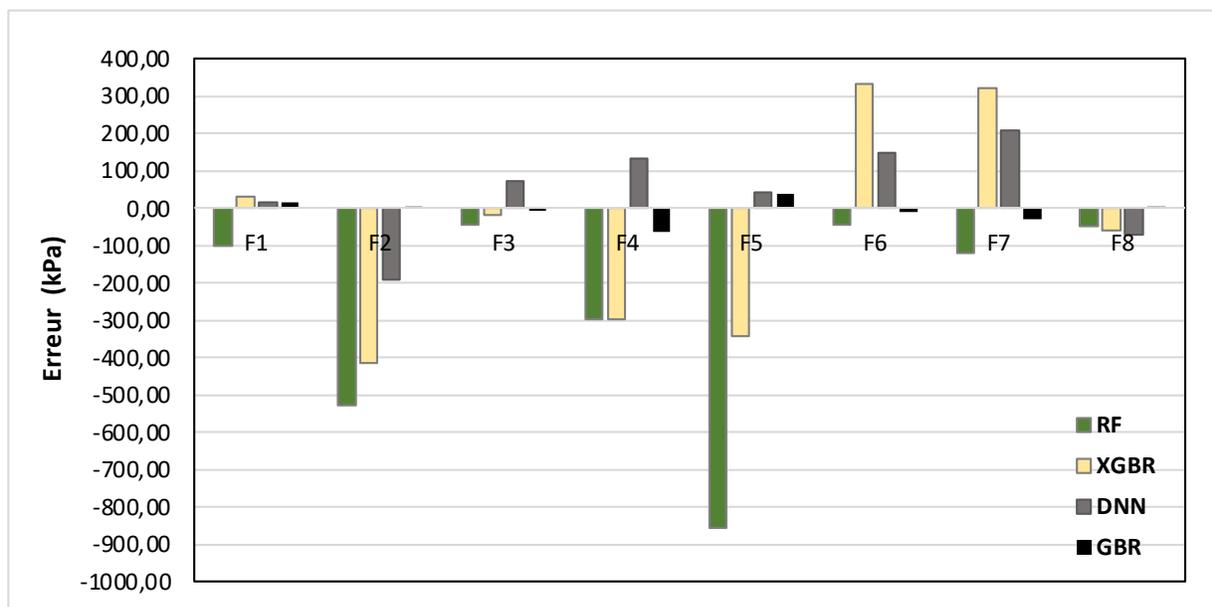


Figure 4-27 Erreurs de prédiction des modèles

En récapitulant les indicateurs de performances des modèles (métriques), dans l'histogramme de la Figure 4-28 et le Tableau 4-7, et en se basant aussi sur les erreurs de validation de prédictions mentionnées ci-dessus, on sélectionne finalement le GBR et DNN comme deux modèles les plus performants qui seront capables de prédire l'UCS des RPC.

En comparant ces résultats avec ceux obtenus par d'autres chercheurs présentés dans le Tableau 4-8 qui ont développé des modèles de ML sur la base des ensembles de données qui ne dépassent pas 2000 échantillons de RPC (la majorité des travaux ont été faits avec des bases de données ayant 100 à 400 échantillons de RPC). Les limitations de ces travaux résident au niveau de manque de diversité des données au niveau de type de liant utilisé (un type de liant par étude), pourcentage solide, l'affaissement de la pâte du remblai qui représente un paramètre important pour prédire l'UCS, les caractéristiques physiques, minéralogiques et chimiques des résidus (tous ces travaux utilisent la composition chimique des oxydes « *Whole rock* » obtenus par FRX). En ce qui concerne les performances de leurs modèles, tous les coefficients de détermination obtenus entre les valeurs prédites et des valeurs réelles sont attendus vu la taille de la base de données (des petites bases de données). Ce qui rend ces modèles incapables de se généraliser sur prédiction de l'UCS. En outre, ces travaux de recherches se sont limités à développer des modèles intelligents sous forme de lignes de code, ce qui rend ensuite leur manipulation pour effectuer des prédictions difficile.

L'originalité et la robustesse de notre étude se situent d'une part au niveau la quantité des données (laboratoire et minière) et leurs qualités (une vaste diversité des variables) et d'autre part au niveau des performances des modèles obtenus sur ces mégadonnées ainsi que la validation de ces derniers à l'échelle laboratoire. Finalement, l'opérationnalisation du modèle de prédiction le plus performant par le développement d'une application web.

Il faut retenir que ces modèles peuvent être améliorés par l'ajout et l'ajustement des données. Ce qui rend les projets de ML toujours en progression et il faut les suivre et les mettre à jour régulièrement une fois déployer.

Tableau 4-7 Coefficient de corrélation (R) des modèles

Modèles	R
DNN	0.9692
GBR	0.9701
XGBR	0.9635
RF	0.9588

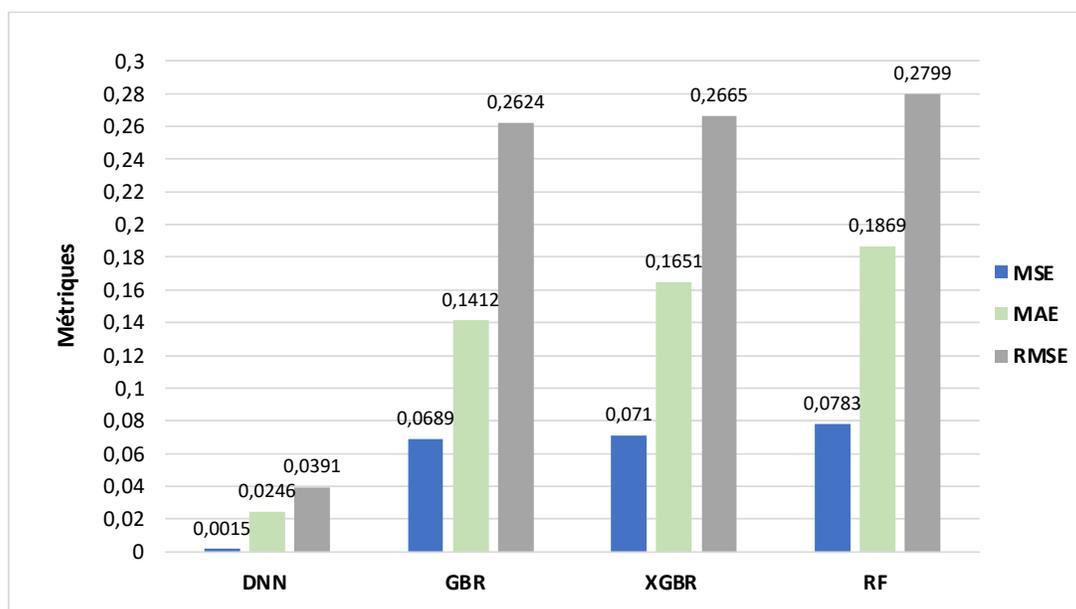


Figure 4-28 Comparaison des performances des modèles

Tableau 4-8 Comparaison avec d'autres résultats à vérifier

Auteurs	Modèles de prédiction	Taille de BD	Sources des données	Données d'entrées	Temps de cure (jours)	Performance de prédiction
Qi et al. (2023)	DNN	986	Données de littérature et expérimentales	C-P-C-R ^a CTR ^b MC ^c T ^d	1 à 360	R = 0.967
Arachchilage et al. (2023)	GBR, RF, SVR ANN	307	Données de littérature et expérimentales	C-P-C-R CTR MC T	7 à 224	R ² _{GBR} = 0.960
Hu et al. (2022)	SSA-ELM ELM PSO-ELM BP-ANN	51	Données expérimentales	Température CTR SC ^h T	7 à 28	R ² _{SSA-ELM} = 0.9979
Sun et al. (2020)	BSVM	435	Données expérimentales	T/C ^e S/W ^f FTP ^g T	6 à 60	R = 0.97

(Li et al., 2021)	SVM	144	Données expérimentales	CTR	3 et 28	$R^2_{SSA-SVM} = 0.9475$
	GA			MC		
	SSA			T		
	GS			CF		
	PSO					
(Yu et al., 2021)	SSA-ELM	720	Données expérimentales	CTR	3, 7 et 28	$R_{ANN} = 0.9183$
	SVR,			MC		
	ANN			T		
				CF ⁱ		
(Qiu et al., 2020)	GSO-RF	144	Données expérimentales	CTR	3,7, 14 et 28	$R^2 = 0.9586$
				MC		
				T		
				Dosage de liant		
(Qi et al., 2020)	GBRT-PSO	132	Données expérimentales	CTR	7 et 28	$R = 0.991$
				MC		
				T		
				Type de liant		
(Liu et al., 2020)	SVM	870	Données expérimentales	CTR	28 et 60	$R_{BPNN} = 0.9831$
	DT			S/W		
	RF			FTP		
	BPNN			T		
	KNN					
	LR					
	MLR					

(Lu et al., 2019)	RT	126	Données de littérature et expérimentales	CTR	3,7, 14 et 28	$R_{GBRT} = 0.9837$
	RF			MC		
	GBRT			T		
(Qi et al., 2019)	GA	1545	Données expérimentales	C-P-C-R	3 à 60	$R_{GA} = 0.94$
	GBR			CTR		
	RF			SC		
	DT			T		
(Qi et al., 2018b)	GBM	1077	Données expérimentales	C-P-C-R	3 à 60	$R = 0.963$
				CTR		
				SC		
				T		
				E ^j		
YS ^k						
(Qi et al., 2018c)	ANN-PSO	396	Données expérimentales	CTR	3, 7 et 28	$R = 0.979$
				SC		
				T		
				Type de liant		
(Qi et al., 2018d)	BRT-PSO	585	Données expérimentales	C-P-C-R	7 et 28	$R = 0.96$
				CTR		
				SC		
				T		

^a Caractérisation physique et chimique des résidus, ^b Ratio ciment-résidus, ^c Concentration massique, ^d Temps de cure, ^e Rapport résidus grossiers-ciment, ^f Ratio solide-eau, ^g Pourcentage de résidus fins, ^h Pourcentage de solide, ⁱ Caractéristique des fibres, ^j Module de Young, ^k Limite d'élasticité

4.3.5 Déploiement du modèle performant pour la prédiction de l'UCS

L'implémentation des modèles d'apprentissage automatique et des réseaux de neurones artificiels sous forme de lignes de code n'est actuellement pas fonctionnelle pour l'industrie minière. Cependant, il est souhaitable de développer des outils permettant de déployer ces modèles en production. Cette étude de recherche a pour objectif de contribuer à cette démarche en créant une application Web, basée sur le modèle GradientBoostingRegressor (GBR), reconnu comme le plus fiable. L'interface de l'application, présentée dans la Figure 4-29, permet aux utilisateurs d'entrer les caractéristiques physiques, minéralogiques et chimiques des résidus et de l'eau de mélange, ainsi que les paramètres du mélange (type de liant, proportion, pourcentage de solides, affaissement) et le temps de cure. En se basant sur son apprentissage, le modèle prédit l'UCS qui est affiché en bas de l'interface.

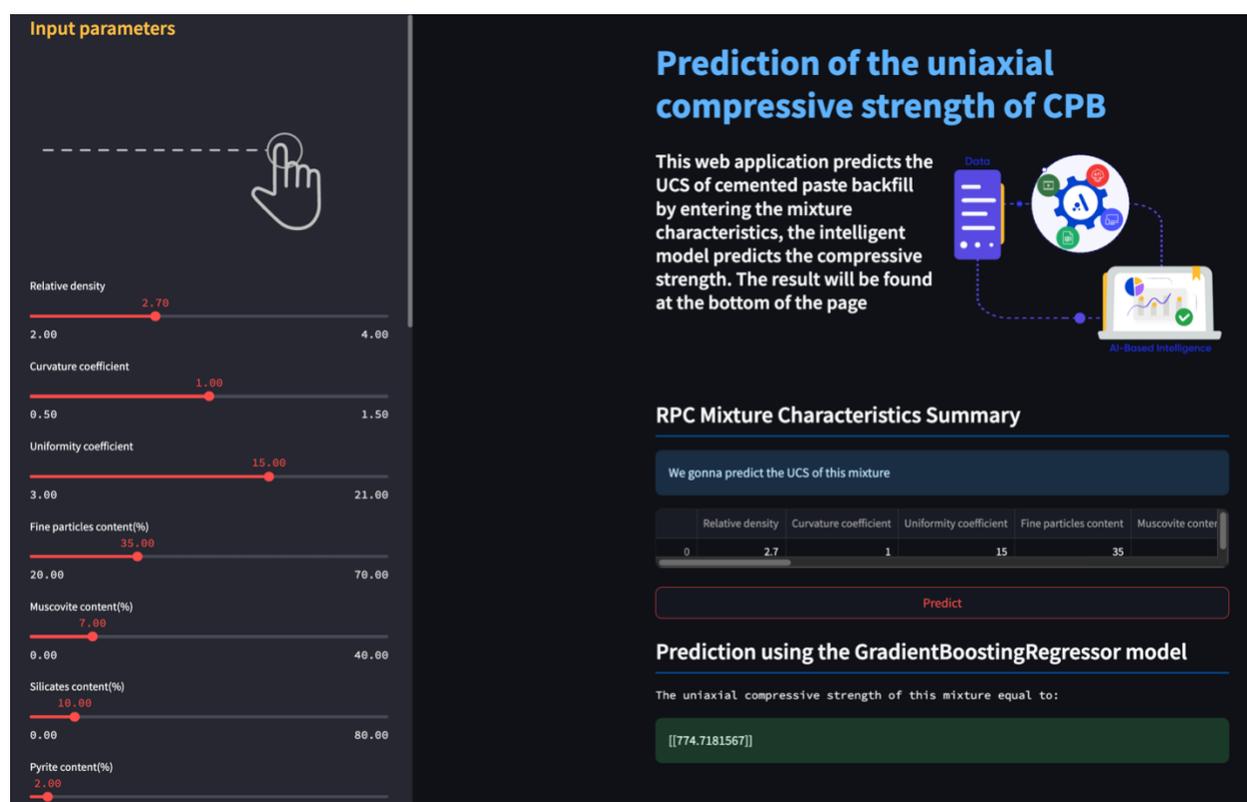


Figure 4-29 Interface de l'application web

Dans le but d'opérationnaliser le modèle GBR, on a exécuté l'application Web où s'intègre la base de données et le modèle pour faire des prédictions de la résistance à la compression uniaxiale des mélanges de RPC réalisés à base de résidus du gisement Upper Beaver près de la mine Macassa de la compagnie minière Agnico Eagle. Au total, on a prédit 21 formulations de RPC faites avec le liant composé 10GU/90Slag, avec différents pourcentages de liant $B_w(\%)$ à savoir 3, 4, 5 et 7%. Les pourcentages de solides étaient de 78,2; 78,4; 78,5%; 79,1; 79,2 et 79,3 % qui correspond à des affaissements égales à 8,3; 7,2; 7 et 6,9 po. Les échantillons ont été placés sous cure pendant des périodes égales à 7, 28, 56 et 180 jours.

La Figure 4-30 représente la comparaison entre les UCS prédites par le modèle et les UCS réelles obtenues au laboratoire. Il est évident que le modèle est capable de générer des prédictions précises avec une erreur moyenne absolue de 44.94 kPa (≈ 45 kPa).

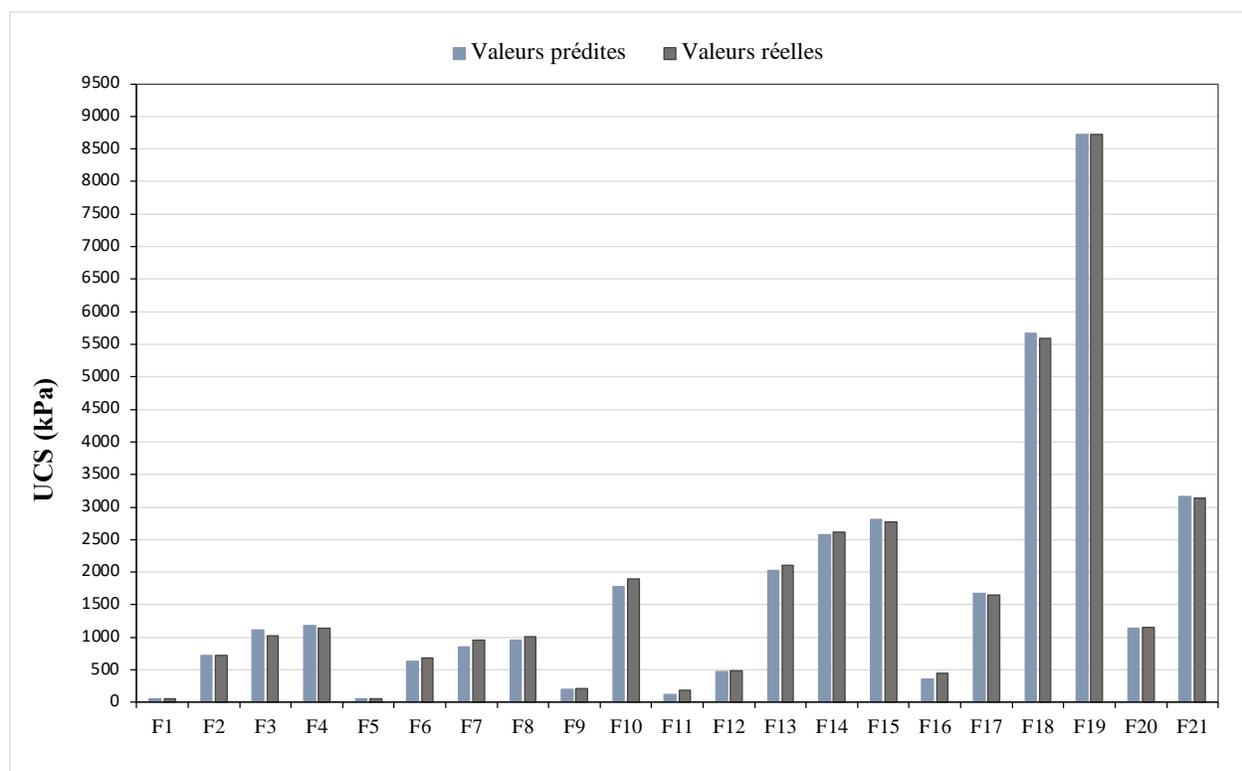


Figure 4-30 Prédiction de l'UCS du RPC à base des résidus de la mine Upper Beaver à l'aide du modèle GBR

CHAPITRE 5 CONCLUSIONS ET RECOMMANDATIONS

5.1 Conclusion

L'intelligence artificielle représente le progrès le plus puissant de l'humanité à ce jour, on trouve son intégration dans divers domaines (industriel, médical, policier, financier, etc.).

Cependant, elle reste très peu développée dans l'industrie minière, de l'exploration jusqu'à l'exploitation particulièrement au niveau de suivi des opérations souterraines, détection des anomalies (événements sismiques, défaut dans de divers systèmes mécaniques) dans le but d'assurer la sécurité des travailleurs et d'améliorer la productivité.

Vu la nécessité d'utilisation des matériaux de remblayage pour l'extraction des minerais, la connaissance et l'étude des différentes propriétés (mécaniques, rhéologiques, physiques, etc.) de ces matériaux reste un problème de recherche et plus précisément la prédiction des propriétés mécaniques de remblai en pâte cimenté. En effet, c'est un matériau destiné au remblayage des excavations souterraines, il représente le type de remblai le plus couramment utilisé dans les mines grâce à ses divers avantages. En outre, la résistance à la compression uniaxiale (UCS) est la propriété la plus importante qui caractérise son comportement mécanique et la prédiction de cette dernière reste jusqu'à aujourd'hui un grand défi.

Avec les mégadonnées générées par l'industrie minière, il serait utile de les utiliser pour le développement des systèmes intelligents. Dans cet optique, s'inscrit l'objectif de cette étude de recherche de développer des modèles intelligents basés sur l'apprentissage automatique et l'apprentissage profond pour prédire la résistance à la compression uniaxiale des remblais en pâte cimentés. La méthodologie de ce travail se divise en deux grandes parties; la première partie est conçue aux travaux de laboratoire à savoir l'homogénéisation des cinq résidus, leurs caractérisations physiques (densité relative et granulométrie). Une fois déterminés les paramètres physiques, les différents mélanges de remblais en pâte cimentés ont été préparés avec un pourcentage de solide ($C_w\%$) qui varie entre 70% et 77% et trois pourcentages de liant 3, 5.5 et 8% de façon que l'affaissement mesuré était entre 5.75 po et 12 po. Ensuite, ces mélanges ont été versés dans des moules plastiques (3 po de diamètre et 6 po de hauteur) et stockés dans une chambre humide. Quatre temps de cure ont été considérés à savoir 14, 28, 56 et 90 jours pour effectuer les essais de compression uniaxiale. Après la collecte des tous les résultats de laboratoire et d'autres

données en provenance des mines de la compagnie Agnico Eagle, la deuxième étape de ce projet est dédiée à la programmation et le développement. En effet la première phase était une analyse exploratoire bien détaillée de la base de données construite telle que la gestion des données manquantes, l'analyse de distribution et corrélation des données, ainsi que la transformation des données pour pouvoir développer nos modèles de *Machine Learning* et le réseau de neurones profond (*Deep Neural Network*) et optimiser leurs hyperparamètres.

Les principaux résultats de cette étude ont montré que :

- Le type de liant ainsi que sa proportion ont un effet significatif sur l'UCS. En effet le liant composé 20GU/80Slag a développé les meilleures résistances à la compression uniaxiale de RPC. Ce type de liant a été recommandé dans la majorité des mines pour fabriquer le remblai cimenté.
- En se basant sur la caractérisation physique des résidus, on a pu montrer l'effet néfaste des proportions des particules fines ($P_{20\mu m}$). Les résidus ayant de faibles proportions des particules fines ont développé des résistances meilleures que ceux ayant de fortes proportions des particules fines.
- À partir des méthodes de visualisations, on a pu détecter des valeurs manquantes dans la base de données qui ont été toutes supprimées en gardant les données les plus récentes.
- Toutes les variables dans la base de données avaient des distributions ni uniforme, ni gaussienne ce qui nous exige de faire des transformations de ces variables de façon qu'elles auront des distributions gaussiennes en les mettant sur la même échelle pour minimiser l'effet des valeurs aberrantes et par conséquent d'assurer un bon apprentissage des modèles.
- L'analyse de corrélation a montré des corrélations fortement positives entre l'UCS et le pourcentage de solide, le pourcentage de liant, l'affaissement, temps de cure, coefficient de courbure, coefficient d'uniformité et le taux de substitution de liant GU par le Slag. Cependant, des corrélations fortement négatives ont été enregistrées entre l'UCS et la densité relative, le pourcentage des particules des particules, la teneur en muscovite, la teneur en silicates, la teneur en sulfates dans les eaux, le taux de ciment GU ainsi que le taux des scories de type F et C dans le liant composé.

- L'optimisation des hyperparamètres des modèles a été effectuée à l'aide de la méthode de recherche aléatoire suivie par une validation croisée.
- Des indicateurs des performances et des courbes d'apprentissage des modèles montrent que ces derniers ont été robustes au cours de leurs apprentissages et qu'ils sont capables de se généraliser pour prédire l'UCS ce qui valide la première hypothèse de recherche. Toutes fois, les résultats de validation ont montré que les modèles les plus performants sont le GBR et DNN qui ont prédit des UCS proches de celles obtenues au laboratoire qui ont donné des coefficients de détermination respectivement égale à 0.9701 et 0.9692.
- Par la comparaison avec d'autres travaux de recherche, on a pu montrer que les performances de tous les modèles d'apprentissage automatique et les réseaux de neurones artificiels dépendent de la taille des bases de données sur lesquelles ces modèles ont été entraînés ainsi que la qualité des données (diversité) ce qui approuve la deuxième hypothèse de recherche.

5.2 Retombées et recommandations

Le long de cette maîtrise, ce projet a été présenté dans diverses conférences à savoir :

- 25e Conférence internationale sur les résidus en pâte (PASTE 2023), épaissis à Banff, Alberta, Canada pour présenter un article de conférence (Annexe C).
- Le colloque du Centre de recherche sur les infrastructures en béton (CRIB) à l'université de Laval en gagnant le premier prix du meilleur projet de recherche;
- Le colloque du Centre de recherche sur les infrastructures en béton (CRIB) à Rouyn-Noranda;
- Colloque annuel de l'IRME;

Il sera également présenté lors du 14e Symposium international sur l'exploitation minière avec le remblai (Minefill 2024) à Vancouver, British Columbia, Canada.

Ce projet a réussi à de nombreux résultats vitaux sur le plan industriel, il permet d'acquérir de nouvelles technologies (intelligence artificielle) pour l'industrie minière et les firmes de génie-

conseil. Comme mentionné ci-dessus, les mines génèrent une énorme quantité des données. Ces dernières seront utiles pour développer divers systèmes intelligents pour :

- Prédire les propriétés mécaniques des remblais rocheux et massives rocheux,
- Détection des défaillances dans les pipelines, des barricades de soutènement et des masses de remblais, etc.
- Le contrôle de qualités des opérations souterraines.

RÉFÉRENCES BIBLIOGRAPHIQUES

- Amini, M.-R., Blanch, R., Clausel, M., Durand, J.-B., Gaussier, E., Christophe Picard, J.M., Quéma, V., Quénot, G., 2018. Data science. Eyrolles, Paris.
- Amriou, A., Bencheikh, M., Messaoudene, I., Deboucha, S., Ziani, H., 2019. Évaluation de l'influence du pourcentage de sable et du ciment sur la résistance à la compression du BTC.
- Andradóttir, S., 2006. Chapter 20 An Overview of Simulation Optimization via Random Search, in: Handbooks in Operations Research and Management Science. Elsevier, pp. 617–631. [https://doi.org/10.1016/S0927-0507\(06\)13020-0](https://doi.org/10.1016/S0927-0507(06)13020-0)
- Arachchilage, C.B., Fan, C., Zhao, J., Huang, G., Liu, W.V., 2023. A machine learning model to predict unconfined compressive strength of alkali-activated slag-based cemented paste backfill. *J. Rock Mech. Geotech. Eng.* 15, 2803–2815. <https://doi.org/10.1016/j.jrmge.2022.12.009>
- Archibald, J.F., Hassani, F., Nantel, J., DeGagné, D.O., 1998. Mine Backfill, An Operator's Guide. An interactive CD-ROM for mine operators and engineers.
- Arioglu, E., 1983. Engineering properties of cemented aggregate fill for Uludag tungsten mine of Turkey. Proceedings of the International Symposium on Mining with Backfill.
- Asoodeh, M., Bagheripour, P., 2012. Prediction of Compressional, Shear, and Stoneley Wave Velocities from Conventional Well Log Data Using a Committee Machine with Intelligent Systems. *Rock Mech. Rock Eng.* 45, 45–63. <https://doi.org/10.1007/s00603-011-0181-2>
- ASTM International, 2021. Standard Test Method for Compressive Strength of Cylindrical Concrete Specimens (ASTM C39/C39M-21). ASTM International, West Conshohoken.
- ASTM International, 2020. Standard Test Method for Slump of Hydraulic-Cement Concrete (ASTM C143/C143M-20), ASTM. International, West Conshohoken.
- Aubé, B., 2004. Une étude en usine pilote de la production de boues à haute densité durant le traitement des eaux de drainage minier acide. Université de Montréal.
- Belem, T., 2009. Développement d'une méthode intégrée d'analyse de stabilité des chantiers miniers remblayés. Institut de recherche en santé et en sécurité du travail du Québec (IRSST). Rapport No R-622, Quebec, pp. 1-97.
- Belem, T., Benzaazoua, M., 2008a. Design and Application of Underground Mine Paste Backfill Technology. *Geotech. Geol. Eng.* 26, 147–174. <https://doi.org/10.1007/s10706-007-9154-3>
- Belem, T., Benzaazoua, M., 2008b. Design and Application of Underground Mine Paste Backfill

- Technology. *Geotech. Geol. Eng.* 26, 147–174. <https://doi.org/10.1007/s10706-007-9154-3>
- Belem, T., Benzaazoua, M., 2003a. Utilisation du remblai en pâte comme support de terrain. Partie i: de sa fabrication à sa mise en place sous terre.
- Belem, T., Benzaazoua, M., 2003b. Utilisation du remblai en pâte comme support de terrain. Partie I : de sa fabrication à sa mise en place sous terre.
- Belem, T., Benzaazoua, M.B., Bussière, B., 2000a. Mechanical behaviour of cemented paste backfill. *Rock Mech.* 1.
- Belem, T., Benzaazoua, M.B., Bussière, B., 2000b. Mechanical behaviour of cemented paste backfill. *ROCK Mech.* 1.
- Benzaazoua, M., Belem, T., Bussière, B., 2002. Chemical factors that influence the performance of mine sulphidic paste backfill. *Cem. Concr. Res.* 32, 1133–1144. [https://doi.org/10.1016/S0008-8846\(02\)00752-4](https://doi.org/10.1016/S0008-8846(02)00752-4)
- Benzaazoua, M., Bois, D., Belem, T., Gauthier, P., Ouellet, S., Bussière, B., Fall, M., Aubertin, M., St-Onge, J.-F., 2005. Remblais souterrains, évolution des connaissances et de la pratique.
- Benzaazoua, M., Ouellet, J., Servant, S., Newman, P., Verburg, R., 1999a. Cementitious backfill with high sulfur content Physical, chemical, and mineralogical characterization. *Cem. Concr. Res.* 29, 719–725. [https://doi.org/10.1016/S0008-8846\(99\)00023-X](https://doi.org/10.1016/S0008-8846(99)00023-X)
- Benzaazoua, M., Ouellet, J., Servant, S., Newman, P., Verburg, R., 1999b. Cementitious backfill with high sulfur content Physical, chemical, and mineralogical characterization. *Cem. Concr. Res.* 29, 719–725. [https://doi.org/10.1016/S0008-8846\(99\)00023-X](https://doi.org/10.1016/S0008-8846(99)00023-X)
- Bernier, R.L., Li, M.G., Moerman, A., 1999. Effects of tailings and binder geochemistry on the physical strength of paste backfill. *Proc Sudbury 99*, 1113–1122.
- Bouzoubaâ, N., Foo, S., 2004. Use of Fly Ash and Slag in Concrete: A Best Practice Guide.
- Bowker, L.N., Chambers, D.M., 2015. The risk, public liability & economies of tailings storage facility failures. Research Paper. Stonington, ME.
- Bussière, B., 2007. Colloquium 2004: Hydrogeotechnical properties of hard rock tailings from metal mines and emerging geoenvironmental disposal approaches. *Can. Geotech. J.* 44, 1019–1052. <https://doi.org/10.1139/T07-040>
- Chen, T., Guestrin, C., 2016. XGBoost: A Scalable Tree Boosting System, in: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. pp. 785–794. <https://doi.org/10.1145/2939672.2939785>

- Chollet François, 2020. L'apprentissage profond avec Python.
- Djeriri, Y., 2017. Les Réseaux de Neurones Artificiels. University of Sidi-Bel-Abbes.
- Droniou, A., 2015. Apprentissage de représentations et robotique développementale: quelques apports de l'apprentissage profond pour la robotique autonome.
- Duan, Y., Shen, Y., Canbulat, I., Luo, X., Si, G., 2021. Classification of clustered microseismic events in a coal mine using machine learning. *J. Rock Mech. Geotech. Eng.* 13, 1256–1273. <https://doi.org/10.1016/j.jrmge.2021.09.002>
- Fall, M., Benzaazoua, M., 2005a. Modeling the effect of sulphate on strength development of paste backfill and binder mixture optimization. *Cem. Concr. Res.* 35, 301–314. <https://doi.org/10.1016/j.cemconres.2004.05.020>
- Fall, M., Benzaazoua, M., 2005b. Modeling the effect of sulphate on strength development of paste backfill and binder mixture optimization. *Cem. Concr. Res.* 35, 301–314. <https://doi.org/10.1016/j.cemconres.2004.05.020>
- Fall, M., Benzaazoua, M., 2003. Advances in predicting performance properties and cost of paste backfill. Presented at the Tailings and mine waste '03, pp. 73–85.
- Fall, M., Benzaazoua, M., Ouellet, S., 2005. Experimental characterization of the influence of tailings fineness and density on the quality of cemented paste backfill. *Miner. Eng.* 18, 41–44. <https://doi.org/10.1016/j.mineng.2004.05.012>
- Fall, M., Benzaazoua, M., Ouellet, S., 2004. Effect of tailings properties on paste backfill performance.
- Fall, M., Benzaazoua, M., Ouellet, S., 2004. Effect of tailings of paste backfill properties, in: *International Symposium Mine Fill*.
- Farhadi, F., 2017. Learning Activation Functions in Deep Neural Networks. Ecole Polytechnique, Montreal (Canada).
- Friedman, J.H., 2001. Greedy function approximation: a gradient boosting machine. *Annals of statistics*, 1189-1232.
- Gauthier, P., 2004. Valorisation des liants et des rejets industriels dans les remblais miniers. Thesis Univ. Qué. En Abitibi-Témiscamingue Rouyn-Noranda Can.
- Grus, J., 2020. Data science par la pratique: fondamentaux avec Python, 2e éd. ed. Eyrolles, Paris.
- Hassani, F.P., Ouellet, J., Hossein, M., 2001. Strength development in underground high-sulphate paste backfill operation. *CIM Bull.* 94.

- Hong, Y., Kang, J., Fu, C., 2022. Rapid prediction of mine tunnel fire smoke movement with machine learning and supercomputing techniques. *Fire Saf. J.* 127, 103492. <https://doi.org/10.1016/j.firesaf.2021.103492>
- Hu, Y., Li, K., Zhang, B., Han, B., 2022. Strength investigation of the cemented paste backfill in alpine regions using lab experiments and machine learning. *Constr. Build. Mater.* 323, 126583. <https://doi.org/10.1016/j.conbuildmat.2022.126583>
- Hyder, Z., Siau, K., Nah, F., 2019. Artificial intelligence, machine learning, and autonomous technologies in mining industry. *J. Database Manag. JDM* 30, 67–79.
- Jiang, Q., Feng, X.-T., Xiang, T.-B., Su, G.-S., 2010. Rockburst characteristics and numerical simulation based on a new energy index: a case study of a tunnel at 2,500 m depth. *Bull. Eng. Geol. Environ.* 69, 381–388. <https://doi.org/10.1007/s10064-010-0275-1>
- John, G.H., 1995. *Robust Decision Trees: Removing Outliers from Databases*. Computer Science Dept. Stanford University.
- Jordan, M.I., Mitchell, T.M., 2015. Machine learning: Trends, perspectives, and prospects. *Science* 349, 255–260. <https://doi.org/10.1126/science.aaa8415>
- Khandelwal, M., Monjezi, M., 2013. Prediction of Backbreak in Open-Pit Blasting Operations Using the Machine Learning Method. *Rock Mech. Rock Eng.* 46, 389–396. <https://doi.org/10.1007/s00603-012-0269-3>
- Lacombe, T., 2018. *Exploitation d'une information multiéclairages pour une approche générique de l'inspection automatique de la qualité visuelle des produits en industrie*. Thèse de doctorat.
- Laloë, T., 2009. *Sur quelques problèmes d'apprentissage supervisé et non supervisé*.
- Lamos, A., Clark, I., 1989. The influence of material composition and sample geometry on the strength of cemented backfill. *Innovations in Mining Backfill Technology*.
- Landriault, D.A., Verburg, R., Cincilla, W., Welch, D., 1997. *Paste technology for underground backfill and surface tailings disposal applications*. Technical workshop.
- LeCun, Y., Bengio, Y., Hinton, G., 2015. Deep learning. *nature* 521, 436–444.
- Lerman, P., 1980. Ajustement de modèles de régression segmentés par recherche de grille. *Journal de la Royal Statistical Society Série C : Statistiques appliquées*, 29 (1), 77-84.
- Li, E., Zhou, J., Shi, X., Jahed Armaghani, D., Yu, Z., Chen, X., Huang, P., 2021. Developing a hybrid model of salp swarm algorithm-based support vector machine to predict the strength of fiber-reinforced cemented paste backfill. *Eng. Comput.* 37, 3519–3540.

<https://doi.org/10.1007/s00366-020-01014-x>

- Li, N., Nguyen, H., Rostami, J., Zhang, W., Bui, X.-N., Pradhan, B., 2022. Predicting rock displacement in underground mines using improved machine learning-based models. *Measurement* 188, 110552. <https://doi.org/10.1016/j.measurement.2021.110552>
- Liang, M., Mohamad, E.T., Faradonbeh, R.S., Jahed Armaghani, D., Ghoraba, S., 2016. Rock strength assessment based on regression tree technique. *Eng. Comput.* 32, 343–354. <https://doi.org/10.1007/s00366-015-0429-7>
- Lin, Yun, Zhou, K., Li, J., 2018. Prediction of Slope Stability Using Four Supervised Learning Methods. *IEEE Access* 6, 31169–31179. <https://doi.org/10.1109/ACCESS.2018.2843787>
- Lin, Y., Zhou, K., Li, J., 2018. Application of cloud model in rock burst prediction and performance comparison with three machine learning algorithms. *IEEE Access*, vol. 6, pp. 30958–30968.
- Liu, J., Li, G., Yang, S., Huang, J., 2020. Prediction Models for Evaluating the Strength of Cemented Paste Backfill: A Comparative Study. *Minerals* 10, 1041. <https://doi.org/10.3390/min10111041>
- Lodé, B., Jalaber, C., Orcel, T., Morcet-Delattre, T., Crespin, N., Voisin, S., Billard, F., Luzi, S., Lapotre, T., Lentz, P.-A., Revel, M.-P., Lederlin, M., 2020. Imagerie de la pneumonie COVID-19. *J. Imag. Diagn. Interv.* 3, 249–258. <https://doi.org/10.1016/j.jidi.2020.04.011>
- Lotfi, S., Mesk, H., 2021. Prévission de Défaillance Des entreprises : Apport des Réseaux de Neurones Artificiels. *Int. J. Financ. Account. Econ. Manag. Audit. IJFAEMA* 3, 70–79. <https://doi.org/10.52502/ijfaema.v3i3.53>
- Lu, X., Zhou, W., Ding, X., Shi, X., Luan, B., Li, M., 2019. Ensemble Learning Regression for Estimating Unconfined Compressive Strength of Cemented Paste Backfill. *IEEE Access* 7, 72125–72133. <https://doi.org/10.1109/ACCESS.2019.2918177>
- Majdi, A., Rezaei, M., 2013. Prediction of unconfined compressive strength of rock surrounding a roadway using artificial neural network. *Neural Comput. Appl.* 23, 381–389. <https://doi.org/10.1007/s00521-012-0925-2>
- Mathivet, V., 2021. *Machine Learning: implémentation en Python avec Scikit-learn*. Éditions ENI.
- Mitchell, R.J., 1989. Stability of cemented tailings mine backfills. Presented at the International symposium on computer and physical modelling in geotechnical engineering, pp. 501–508.
- Mohamad, E.T., Jahed Armaghani, D., Momeni, E., Alavi Nezhad Khalil Abad, S.V., 2015. Prediction of the unconfined compressive strength of soft rocks: a PSO-based ANN

approach. *Bull. Eng. Geol. Environ.* 74, 745–757. <https://doi.org/10.1007/s10064-014-0638-0>

- Momeni, E., Jahed Armaghani, D., Hajihassani, M., Mohd Amin, M.F., 2015. Prediction of uniaxial compressive strength of rock samples using hybrid particle swarm optimization-based artificial neural networks. *Measurement* 60, 50–63. <https://doi.org/10.1016/j.measurement.2014.09.075>
- Negara, A., Ali, S., AlDhamen, A., Kesserwan, H., Jin, G., 2017. Unconfined compressive strength prediction from petrophysical properties and elemental spectroscopy using support-vector regression. SPE Kingdom of Saudi Arabia annual technical symposium and exhibition. Society of Petroleum Engineers.
- Newell, A., Simon, H., 1956. The logic theory machine--A complex information processing system. *IEEE Trans. Inf. Theory* 2, 61–79. <https://doi.org/10.1109/TIT.1956.1056797>
- Nyitrai, T., Virág, M., 2019. The effects of handling outliers on the performance of bankruptcy prediction models. *Socioecon. Plann. Sci.* 67, 34–42. <https://doi.org/10.1016/j.seps.2018.08.004>
- Onalo, D.O., 2019. Dynamic data driven investigation of petrophysical and geomechanical properties for reservoir formation evaluation. (Doctoral dissertation, Memorial University of Newfoundland).
- Osborne, J.W., Overbay, A., 2004. The power of outliers (and why researchers should always check for them). <https://doi.org/10.7275/QF69-7K43>
- Ouellet, S., Bussière, B., Aubertin, M., Benzaazoua, M., 2007. Microstructural evolution of cemented paste backfills: Mercury intrusion porosimetry test results. *Cem. Concr. Res.* 37, 1654–1665. <https://doi.org/10.1016/j.cemconres.2007.08.016>
- Pater, J., 2019. Generative linguistics and neural networks at 60: Foundation, friction, and fusion. *Language* 95, e41–e74. <https://doi.org/10.1353/lan.2019.0009>
- Ping-lu, H., Cong-xin, C., Guo-feng, X., Jian, L.I.N., 2009. Study of rock movement caused by underground mining in mines with complicated geological conditions. *Rock Soil Mech.* 30, 3020–3024.
- Qi, C., Chen, Q., Fourie, A., Zhang, Q., 2018a. An intelligent modelling framework for mechanical properties of cemented paste backfill. *Miner. Eng.* 123, 16–27. <https://doi.org/10.1016/j.mineng.2018.04.010>

- Qi, C., Chen, Q., Fourie, A., Zhang, Q., 2018b. An intelligent modelling framework for mechanical properties of cemented paste backfill. *Miner. Eng.* 123, 16–27. <https://doi.org/10.1016/j.mineng.2018.04.010>
- Qi, C., Chen, Q., Sonny Kim, S., 2020. Integrated and intelligent design framework for cemented paste backfill: A combination of robust machine learning modelling and multi-objective optimization. *Miner. Eng.* 155, 106422. <https://doi.org/10.1016/j.mineng.2020.106422>
- Qi, C., Chen, Qi., 2018. Algorithmes évolutifs de forêt aléatoire pour prédire la profondeur de rupture maximale des murs suspendus des chantiers ouverts | Journaux et magazines IEEE | IEEE Xplore [WWW Document]. URL (accessed 9.24.23).
- Qi, C., Fourie, A., Chen, Q., 2018c. Neural network and particle swarm optimization for predicting the unconfined compressive strength of cemented paste backfill. *Constr. Build. Mater.* 159, 473–478. <https://doi.org/10.1016/j.conbuildmat.2017.11.006>
- Qi, C., Fourie, A., Chen, Q., Zhang, Q., 2018d. A strength prediction model using artificial intelligence for recycling waste tailings as cemented paste backfill. *J. Clean. Prod.* 183, 566–578. <https://doi.org/10.1016/j.jclepro.2018.02.154>
- Qi, C., Fourie, A., Ma, G., Tang, X., Du, X., 2018e. Comparative study of hybrid artificial intelligence approaches for predicting hangingwall stability. *Journal of Computing in Civil Engineering*, 32(2), 04017086.
- Qi, C., Tang, X., Dong, X., Chen, Q., Fourie, A., Liu, E., 2019. Towards Intelligent Mining for Backfill: A genetic programming-based method for strength forecasting of cemented paste backfill. *Miner. Eng.* 133, 69–79. <https://doi.org/10.1016/j.mineng.2019.01.004>
- Qi, C., Zheng, J., Yang, X., Chen, Q., Wu, M., 2023. Application of deep neural network in the strength prediction of cemented paste backfill based on a global dataset. *Constr. Build. Mater.* 391, 131827. <https://doi.org/10.1016/j.conbuildmat.2023.131827>
- Qiu, J., Guo, Z., Li, L., Zhang, S., Zhao, Y., Ma, Z., 2020. A Hybrid Artificial Intelligence Model for Predicting the Strength of Foam-Cemented Paste Backfill. *IEEE Access* 8, 84569–84583. <https://doi.org/10.1109/ACCESS.2020.2992595>
- Racoceanu, D., 2006. Contribution à la Surveillance des Systèmes de Production et Utilisant les Techniques de l'Intelligence Artificielle.
- Robitaille, V., Tremblay, D., 1997. Mécanique des sols: théorie et pratique. Modulo.
- Ronowicz, J., Thommes, M., Kleinebudde, P., Krysiński, J., 2015. A data mining approach to

- optimize pellets manufacturing process based on a decision tree algorithm. *Eur. J. Pharm. Sci.* 73, 44–48. <https://doi.org/10.1016/j.ejps.2015.03.013>
- Rosenblatt, F., 1958. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review* 65, 386.
- Sahi, A., 2016. Validation expérimentale d'un modèle de sélection optimale des liants dans la fabrication des remblais miniers cimentés. École Polytechnique, Montréal (Canada).
- Shovic, J.C., Simpson, A., 2021. Python tout en 1 pour les nuls, Pour les nuls. First interactive, Paris.
- Sun, Y., Li, G., Zhang, J., Sun, J., Xu, J., 2020. Development of an Ensemble Intelligent Model for Assessing the Strength of Cemented Paste Backfill. *Adv. Civ. Eng.* 2020, 1–6. <https://doi.org/10.1155/2020/1643529>
- Swan, G., 1985. A new approach to cemented backfill design [WWW Document].
- Tariq, A., 2012. Synergistic and environmental benefits of using cement kiln dust with slag and fly ash in cemented paste tailings. The University of Western Ontario (Canada).
- Tenbergen, R.A., 2000. Techniques de déshydratation des pâtes et conception des circuits des usines de pâtes, in: *Résidus et Déchets Miniers 2000*.
- Toque, F., 2019. Prévission et visualisation de l'affluence dans les transports en commun à l'aide de méthodes d'apprentissage automatique (PhD Thesis). Paris Est.
- Turing, A.M., 1950. Computing Machinery and Intelligence. *Mind* 59, 433–460.
- Ventos, V., Fantun, J.-B., 2021. L'Intelligence Artificielle de confiance au service de la Sécurité: Sécurité Glob. N° 27, 15–27. <https://doi.org/10.3917/secug.213.0015>
- Weizenbaum, J., 1966. Eliza-a computer program for the study of natural language communication between man and machine.
- Wojtecki, Ł., Iwaszenko, S., Apel, D.B., Bukowska, M., Makówka, J., 2022. Use of machine learning algorithms to assess the state of rockburst hazard in underground coal mine openings. *J. Rock Mech. Geotech. Eng.* 14, 703–713. <https://doi.org/10.1016/j.jrmge.2021.10.011>
- Xiao, C., Ye, J., Esteves, R.M., Rong, C., 2016. Using Spearman's correlation coefficients for exploratory data analysis on big dataset. *Concurr. Comput. Pract. Exp.* 28, 3866–3878. <https://doi.org/10.1002/cpe.3745>
- Yilmaz, E., Belem, T., Bussière, B., Benzaazoua, M., 2011. Relationships between microstructural

properties and compressive strength of consolidated and unconsolidated cemented paste backfills. *Cem. Concr. Compos.* 33, 702–715. <https://doi.org/10.1016/j.cemconcomp.2011.03.013>

- Yu, T., 1989. Some factors relating to the stability of consolidated rockfill at Kidd Creek. *Innovations in Mining Backfill Technology*, 279-286.
- Yu, Z., Shi, X., Chen, X., Zhou, J., Qi, C., Chen, Q., Rao, D., 2021. Artificial intelligence model for studying unconfined compressive performance of fiber-reinforced cemented paste backfill. *Trans. Nonferrous Met. Soc. China* 31, 1087–1102. [https://doi.org/10.1016/S1003-6326\(21\)65563-2](https://doi.org/10.1016/S1003-6326(21)65563-2)
- Zabinsky, Z., 2009. Algorithmes de recherche aléatoire. Département d'ingénierie industrielle et des systèmes. Université de Washington, États-Unis.
- Zajac, M., 2007. Etude des relations entre vitesse d'hydratation, texturation des hydrates et résistance mécanique finale des pâtes et micro-mortiers de ciment Portland. Thèse de doctorat en Sciences. Chimie - Physique.
- Zhang, X., Wu, X., Park, Y., Zhang, T., Huang, X., Xiao, F., Usmani, A., 2021. Perspectives of big experimental database and artificial intelligence in tunnel fire research. *Tunn. Undergr. Space Technol.* 108, 103691. <https://doi.org/10.1016/j.tust.2020.103691>
- Zhou, J., Li, X., Mitri, H.S., 2016. Classification of rockburst in underground projects: comparison of ten supervised learning methods. *Journal of Computing in Civil Engineering*, 30(5), 04016003.
- Zhou, J., Shi, X., Du, K., Qiu, X., Li, X., Mitri, H.S., 2017. Feasibility of random-forest approach for prediction of ground settlements induced by the construction of a shield-driven tunnel. *Int. J. Geomech.*

ANNEXES

ANNEXE A - CALCUL DES MÉLANGES

A-1 : Exemple de feuille de calculs des masses des ingrédients du RPC

Tableau A-1 Feuille de calcul Excel pour calculer les masses des ingrédients du RPC

Feuille de calcul des mélanges de remblai en pâte cimenté (RPC) + granulats concassés (RPCg) au laboratoire en fixant le pourcentage solide massique initial du mélange ($C_{w\%}$)			
© Tikou Belem (2016)			
# Projet		PI-Mariem Amri	
Opérateur			
Date		06-10-2022	
Laboratoire		URSTM	
Granulat considéré comme substitut aux résidus (en proportion massique ou volumique)			
note: texte noir, case mauve: à remplir par l'opérateur			
besoin			
Toutes les autres cases ne doivent pas être modifiées (formules de calculs)			
Pour un mélange à slump constant, il est conseillé de partir d'un %solide de 80% (ou autre)			
puis d'ajuster les mélanges en jouant avec l'ajout des ingrédients (selon les résidus et/ou granulats)			
Résidus	LaRonde	Granulats	
Gs résidus	3,180	Gs granulat	3,18
teneur en eau	23,5%		
Cw% résidus	81,0%		
Calcul pour teneur en eau massique			
		tare	1259,0
		tare + mh	1604,7
		tare + ms	1538,9
*obtenue généralement à 50°C après 48h ou à 105°C après 24h			
3%_10GU/90Slag			
# Batch LABO			
diam. moule (pouce)		3	
hauteur du moule (pouce)		6	
nb. moules		9	
% solide initial visé Cw% remblai		75,00%	
Proportion massique de liant (%)		3,00%	
%massique	%m granulat p/r résidus secs (%)	0,00%	
%volumique	%vol granulat p/r résidus secs (%)	0,00%	
%volumique	%vol granulat p/r remblai (%)	0,00%	
eau/liant initial ou W/C initial		7,77	
Facteur de sécurité (%)		25%	
	(T10) GU	3,15	10%
	(T50) HS	3,18	
	(T30) HE	3,15	
	Slag (GGBFS)	2,9	90%
	FA (types C,F)	2,3	
	Chaux	2,6	
Gs résidus + granulat (gr/cc)		3,18	
Gs-liant composé (gr/cc)		2,92	
Gs pâte (résidus+granulat+liant)		3,17	
Volume contenant (cm ³)		695,0	
Volume total pâte V _c (cm ³)		7818,7	
Masse solide calc. M _t (gr)		12054,75	
Sr (%)	Degré de saturation initial (%)	100,0%	
Masse sèche résidus Ms-t (gr)		11703,6	
Masse sèche granulat Ms-g (gr)		0,0	
masse totale liant Mb (gr)		351,1	
masse totale eau Mw (gr)		4018,2	
Masse eau résidus (gr)		2751,3	
masse remblai en pâte (gr)		16073,0	
#Batch 3%_10GU/90Slag			
Masse de granulat sec (gr)		0,0	
Masse résidus humides (gr)		14454,9	
masse eau à ajouter (gr)		1267,0	
Masse liants (gr)	(T10) GU	35,1	
	(T50) HS	0,0	
	(T30) HE	0,0	
	Slag (GGBFS)	316,0	
	FA (types C,F)	0,0	
	Chaux	0,0	

A-2 : Plan de mélange

Tableau A-2 Exemple de plan de mélange utilisé au laboratoire pour préparer les mélanges de RPC

Plan de mélange avec le résidus de LaRonde (C_w=75%)									
	Recette 1 (10GU/90Slag)			Recette 2 (20GU/80Slag)			Recette 3 (30GU/70Slag)		
Proportion de liant B _w	3%	5,50%	7%	3%	5,50%	7%	3%	5,50%	7%
Masse de résidu frais (g)	14454,9	14098,6	13893,1	14456,7	14101,7	13896,9	14458,5	14104,8	13900,7
Masse de ciment GU(g)	35,1	62,8	78,7	70,2	125,6	157,5	105,4	188,4	236,4
Masse de Slag (g)	316,0	565,0	708,7	280,9	502,4	630,1	245,8	439,7	551,5
Masse de liant totale (g)	351,1	627,8	787,4	351,2	628,0	787,6	351,2	628,1	787,8
Masse d'eau à ajouter (g)	1267,0	1330,9	1367,7	1267,1	1331,1	1368,1	1267,3	1331,4	1368,4
Masse de ciment 10GU/90Slag à prendre (g)	351,1	627,8	787,4	312,14	558,19	700,11	273,15	488,53	612,77
Masse de ciment GU à ajouter pour calibrer (g)	0	0	0	39,02	69,77	87,51	78,04	139,58	175,08

Résultats									
Slump mesurée (po)	6,25	7,20	7,00	6,50	7,25	7,50	6,25	7,25	7,25
Slump mesurée (mm)	158,8	182,9	177,8	165,1	184,2	190,5	158,8	184,2	184,2

ANNEXE B – FACTEURS INFLUENÇANT L'UCS

B-1 : Effet du type de liant sur l'UCS

➔ Pour les mélanges de RPC faits avec les résidus de *Westwood* avec $C_w=70\%$

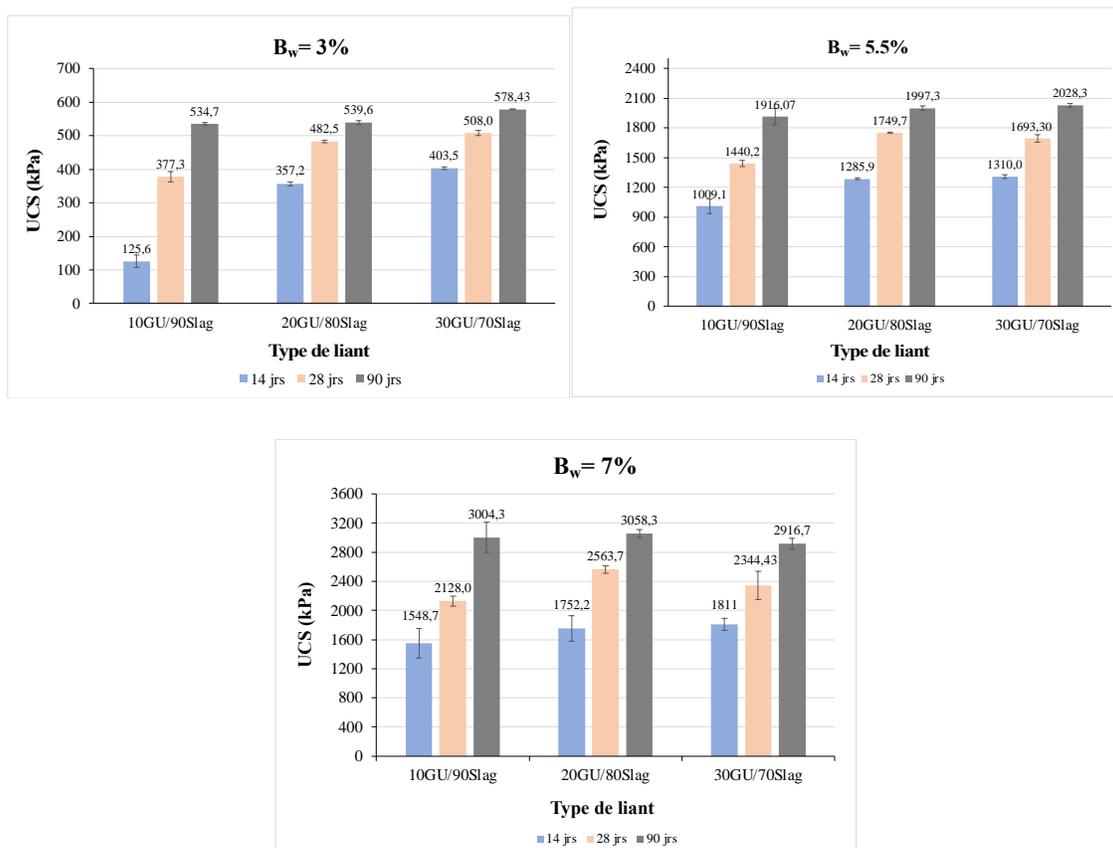
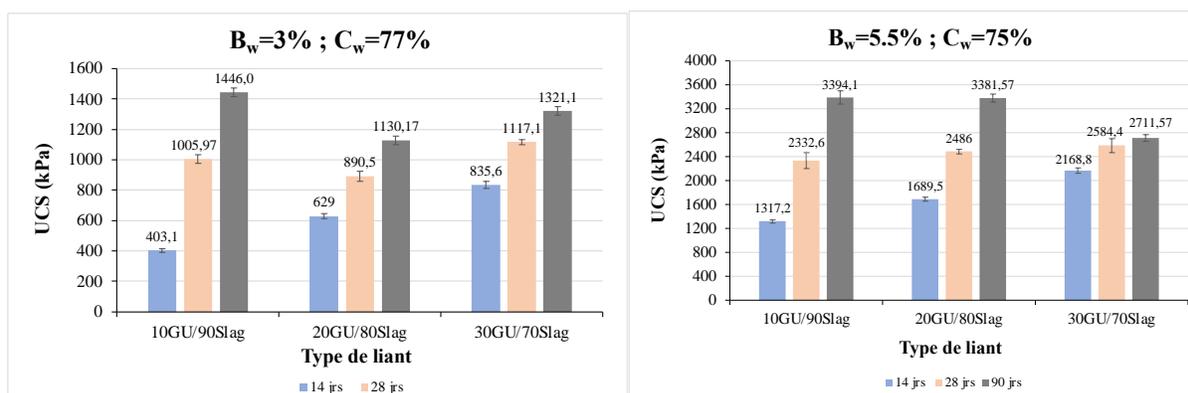


Figure B-1 Évolution de l'UCS en fonction de la formulation de liant GU/Slag

➔ Pour les mélanges de RPC faits avec les résidus de *Goldex*



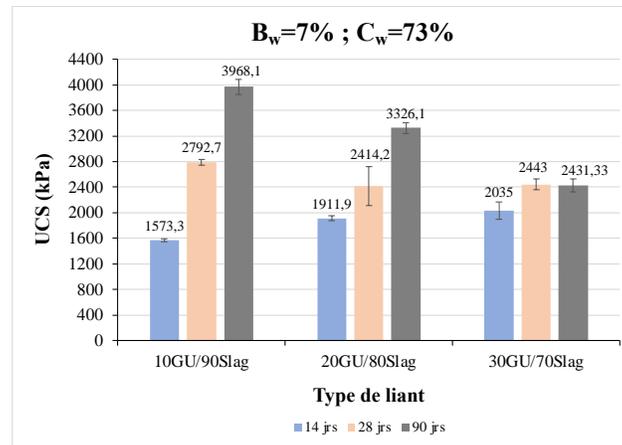


Figure B-2 Évolution de l'UCS en fonction de la formulation de liant GU/Slag

➔ Pour les mélanges de RPC faits avec les résidus de MCM

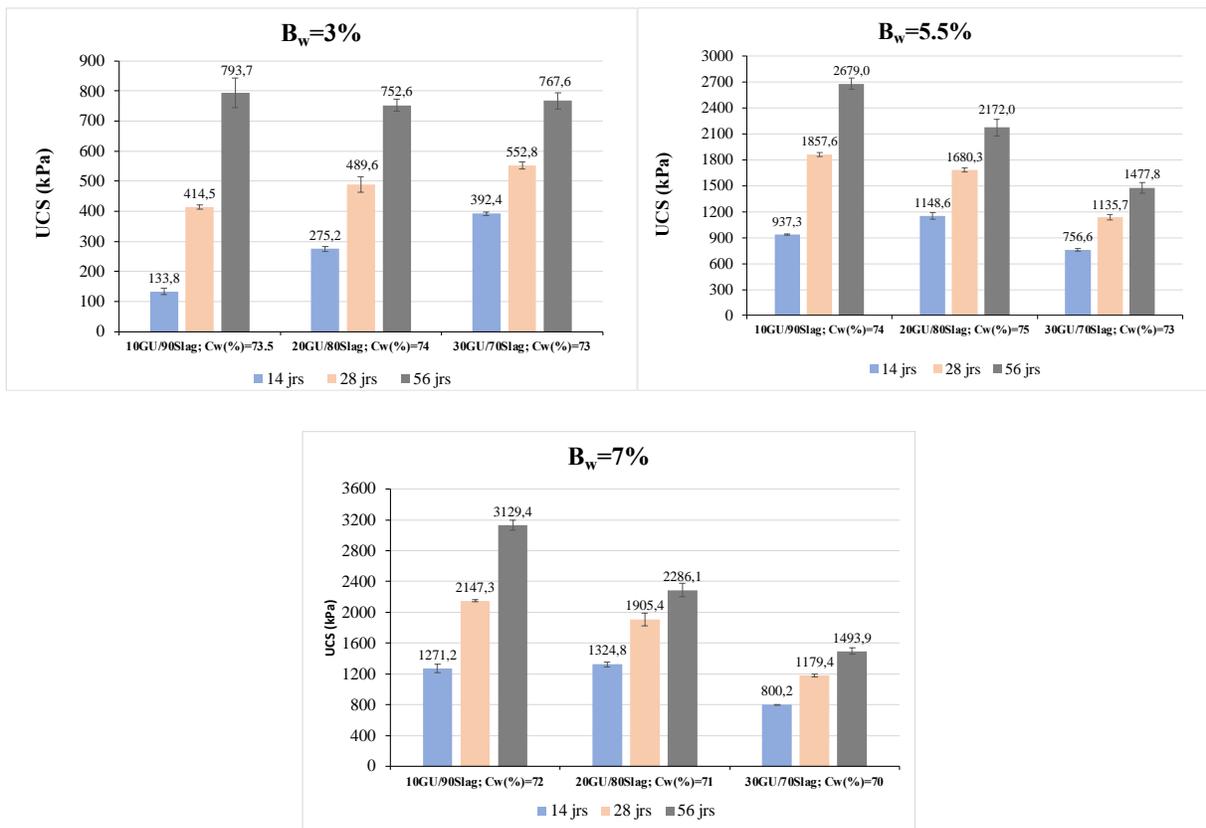


Figure B-3 Évolution de l'UCS en fonction de la formulation de liant GU/Slag

B-2 : Effet de la proportion de liant sur l'UCS

➔ Pour les mélanges de RPC faits avec les résidus de *Westwood* avec $C_w=70\%$

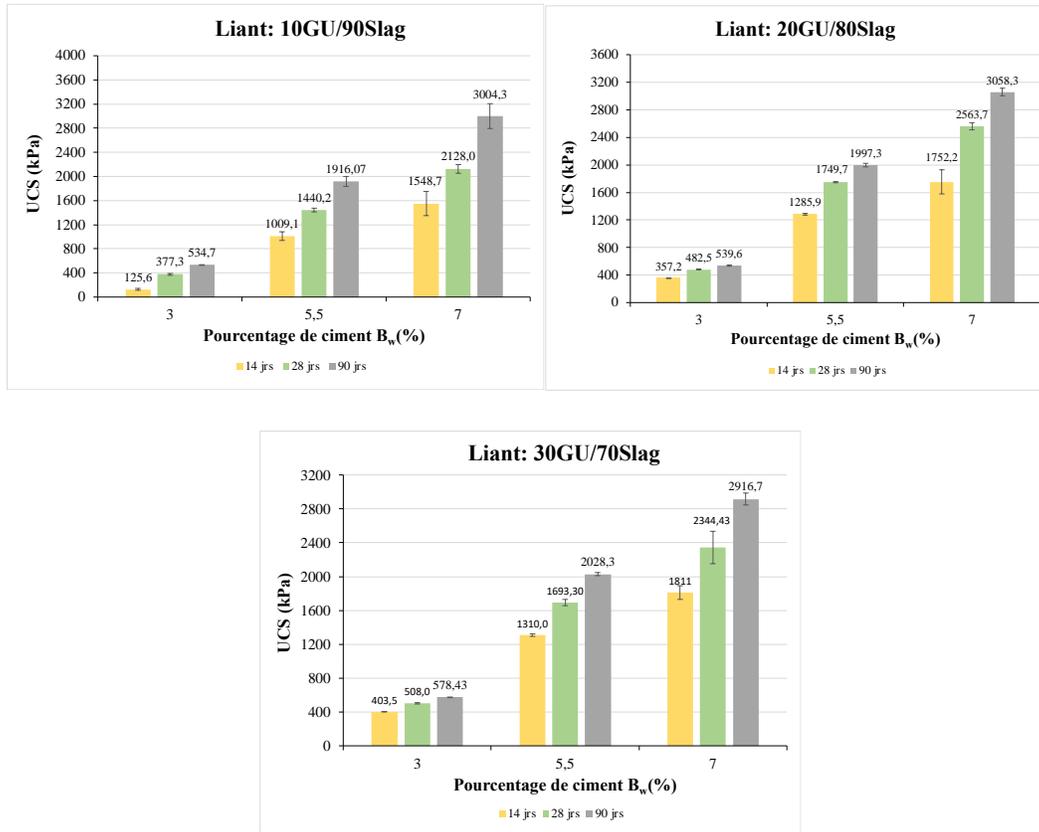
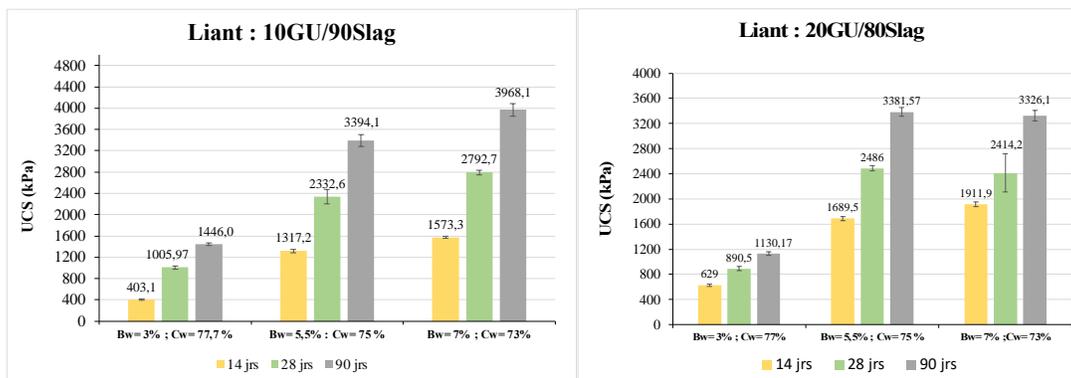


Figure B-4 Évolution de l'UCS en fonction du B_w (%) et temps de cure

➔ Pour les mélanges de RPC faits avec les résidus de *Goldex*



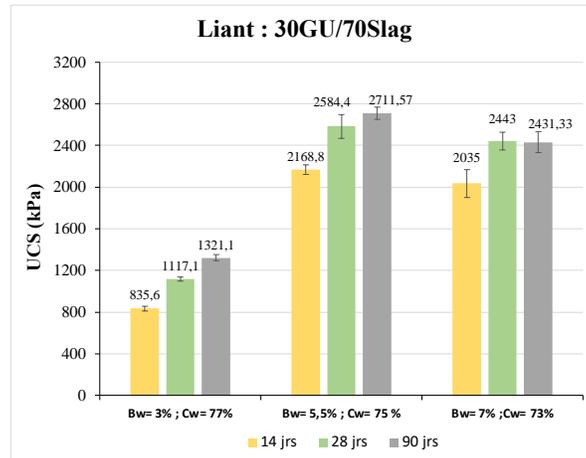


Figure B-5 Évolution de l'UCS en fonction du B_w (%) et temps de cure

➔ Pour les mélanges de RPC faits avec les résidus de *MCM*

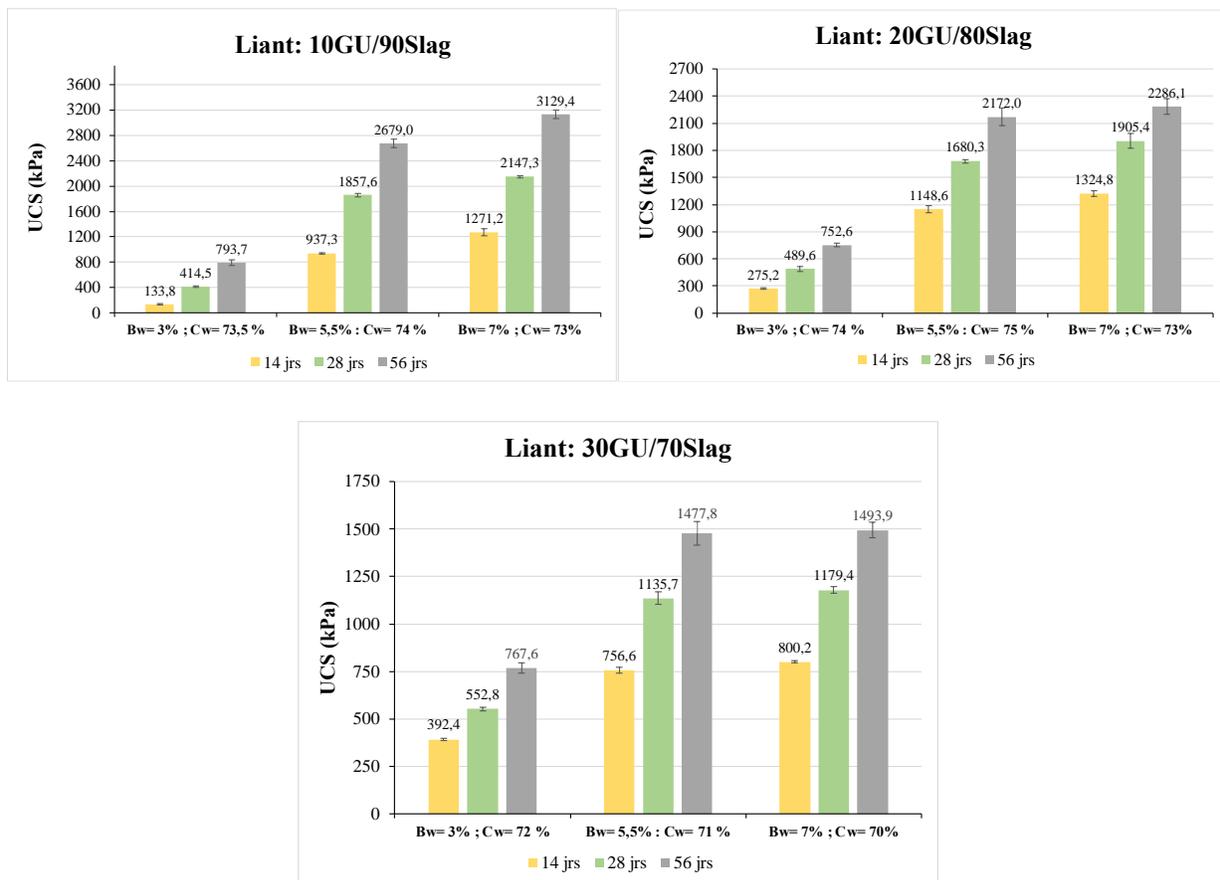


Figure B-6 Évolution de l'UCS en fonction du B_w (%) et du temps de cure

ANNEXE C – ARTICLE DE CONFÉRENCE

Cette annexe présente un article rédigé par Amri, M., Belem, T., Mrad, H., Gélinas, LP., Masmoudi, F., publié à « *Australian Centre for Geomechanics- ACG* » et présentée lors de la 25e Conférence internationale sur les résidus en pâte, épaissis à Banff, Alberta, Canada.

Prediction of the mechanical properties of cemented paste backfill using artificial intelligence approaches

Abstract

In the digital era, the mining industry benefits from powerful tools that can help to optimize underground backfilling operations and to increase overall safety. Indeed, with current progress in artificial intelligence (AI), machine learning (ML) creates state-of-the-art techniques in the mining sector that could significantly improve the productivity and efficiency of mining operations. The purpose of this study is to apply ML algorithms, including the gradient boosting regressor (GBR), the XGBoost regressor (XGBR), and the support vector regressor (SVR) to predict the uniaxial compressive strength (UCS) of cemented paste backfill (CPB). A total of 1,587 UCS data were used to train the ML algorithms, considering different variables such as the types of tailings, binder and their proportion, solid mass concentration, slump height, water quality, and curing time. The raw data were pre-processed before training the models, as well as their hyperparameters tuning was made by a random search method followed by 4-fold cross-validation. The prediction results show that the GBR algorithm is the most powerful one which has a coefficient of correlation (R) between predicted and experimental values equal to 0.99 and a root-mean-square error (RMSE) equal to 0.16. This prediction is validated through new-lab prepared CPB specimens.

Keywords: *artificial intelligence, machine learning, database, prediction models, uniaxial compressive strength, cemented paste backfill*

1 Introduction

Public commitment and recent environmental legislation are becoming increasingly stringent and are constraining mining companies to follow the ‘towards sustainable mining’ standard, which is a globally recognized sustainability program in managing key environmental and social risks of their solid waste storage facilities.

In the case of underground operations, the formulation of mine backfill using these solid wastes is the most widespread approach, not only for filling the underground excavations produced during ore extraction to ensure the ground stability, but also for reducing the huge quantities of mine waste to be stored on the surface. Among the most used worldwide types of mine backfill is the cemented paste backfill (CPB) (e.g. Belem et al. 2003) which is made of tailings, a binding agent (e.g. general use Portland GU cement alone, or a blend of GU with ground granulated blast furnace slag, fly ash, etc.) and mixing water. CPB may also contain chemical admixtures such as superplasticisers (e.g. Ouattara 2017).

For this purpose, knowledge of the mechanical properties of CPB is essential for the implementation of a backfilling system. In practice, uniaxial compressive strength (UCS) is the most used parameter to evaluate the mechanical performance of CPB (e.g. Belem et al. 2003). Various empirical models have been developed to predict the UCS of mine backfill (e.g. Mitchell & Wong 1982; Arioglu 1984; Swan 1985; Lamos

& Clark 1989; Yu 1989), but they are still complex and ignore all the physicochemical properties of the backfill ingredients (i.e. tailings, binder, and mixing water). Other researchers have correlated the UCS with the shear wave velocity using non-destructive tests (ultrasonic pulse velocity [UPV]) (Ercikdi et al. 2014; Yılmaz & Ercikdi 2016), but this method is not robust and has not been well-developed.

More recently, the prediction of the UCS using advanced methods considering the influential parameters (proportion of cement and tailings, solid content, and curing time) has been developed in some studies. Qi et al. (2018a) developed an artificial neural network (ANN) combined with a particle swarm optimization (PSO) algorithm to predict the uniaxial compressive strength of CPB. A total of 396 tests were performed to build the dataset which contains only the types of tailings, cement-to-tailing ratio, solid content, and curing time (3, 7 and 28 days) as input data for the ANN. The prediction coefficient of correlation obtained was 0.979.

Yu et al. (2021) also used ANN, a support vector machine (SVM) model, and a salp swarm algorithm (SSA) optimization algorithm as prediction methods to predict the UCS of CPB reinforced with polypropylene fibres. The dataset used for model training contains 720 UCS tests, cement-to-tailing ratio, solid content, curing time, fibre content, and fibre length were used as input data. The best prediction model ANN combined with the optimization algorithm: SSA-ELM gave a coefficient of determination (R^2) compared to the test data of 0.94 and a root-mean-square error (RMSE) of 0.18.

Lu et al. (2019) combined a machine learning (ML) algorithm gradient boosting regression (GBR) with a PSO optimization algorithm to predict the UCS, of which they used 126 UCS tests from specimens prepared using two types of tailings and the input data that were selected are cement-to-tailing ratio (0.083 to 0.25), solid content (66% to 78%), curing time (3, 7, 14 and 28 days). The prediction score obtained using this algorithm was $R = 0.9837$.

Qi et al. (2018b) used a slightly larger dataset of 1,077 UCS tests and 231 uniaxial tensile strength (UTS) tests to predict the properties of CPB, such as UCS, UTS, elastic modulus, and Young's modulus. They used the genetic algorithm for hyperparameters optimization and three ML algorithms for the prediction: (i) decision tree (DT), (ii) gradient boosting machine (GBM), and (iii) random forest (RF). The results show that the GBM algorithm performs best, giving a correlation coefficient $R = 0.963$.

Mine backfill performance is sensitive to many factors such as the types and the proportion of binder, the mixing water amount and chemistry, the sulphides content, the physicochemical, and the mineralogical properties of the tailings. All the above-mentioned studies have not considered these factors in the database for model learning. Moreover, some mining conditions will require long-term UCS (from 90 to 360 days) data to satisfy the technical requirements of the operations. Long-term curing ages were not considered in any of the cited studies in this paper. The performance of learning algorithms depends strongly on the quantity of data provided (the more data used, the better their performances will be).

Most of the research studies on the prediction of the UCS used small datasets (less than 1,000 UCS tests). However, chemical additives can improve the UCS, GU-Slag compound binder develops much better strengths than GU cement (Sahi 2016). Most of the research has used only one type of binder, which is Portland cement. This shows a lack of diversity in the input data; also, only one type of water has been used (tap water) for the mix recipes formulation.

To remedy the limitations cited in the literature, the present study aims to use advanced ML algorithms for predicting the UCS of CPB based on an extensive dataset containing 1,587 UCS tests. The model predictions will be compared to the existing dataset and evaluated through laboratory tests to select the best-performing model.

2 Methodology

2.1 Materials characterisation

In this study, the ingredients used for the formulation of the CPB were tailings samples from three hard rock mines located in Abitibi-Témiscamingue region in Québec, Canada (namely, T1 = LaRonde mine tailings, T2 = Westwood mine tailings, and T3 = Casa Berardi mine tailings), 10 types of hydraulic binder (GU Portland cement, Slag-blended and type C Fly ash-blended), and different types of water quality (tap water, lake water, and different concentration of sulphated water that are used by the mines).

The tailings used were first homogenized, then their relative density (G_s) was measured using a helium pycnometer AccuPyc II 1340 from Micromeritics. Their particle size distributions (PSD) were determined using a Mastersizer 3000 laser diffraction particle size analyzer from Malvern Panalytical. The PSD curves for the three tailings samples from the three mines are presented in Figures 1, 2, and 3. The mineralogical analysis of these tailings was performed using X-ray diffraction. The physical characteristics and the mineralogical composition of the tailing's samples are summarized in Table 1. In Table 2, xGU means x% GU, γ Slag means γ % Slag, and FA-C means type C fly ash.

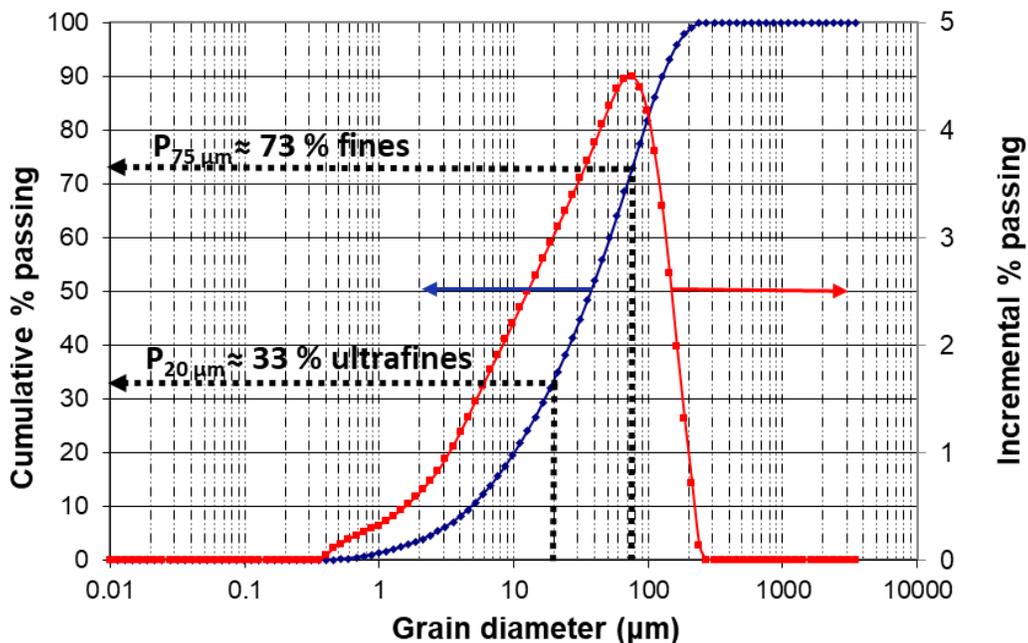


Figure 1 Particle size distribution curve of the LaRonde mine tailings

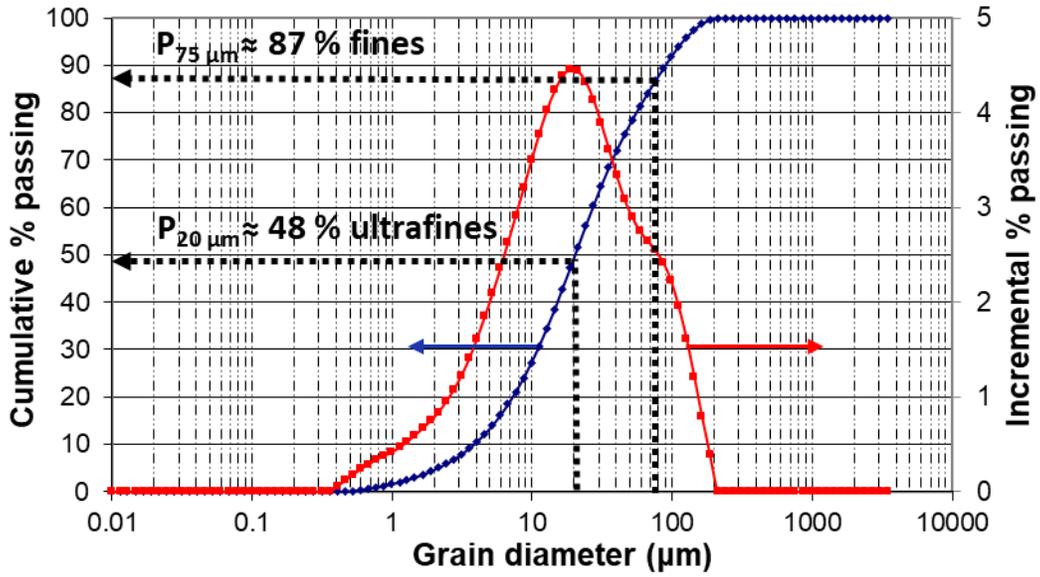


Figure 2 Particle size distribution curve of the Westwood mine tailings

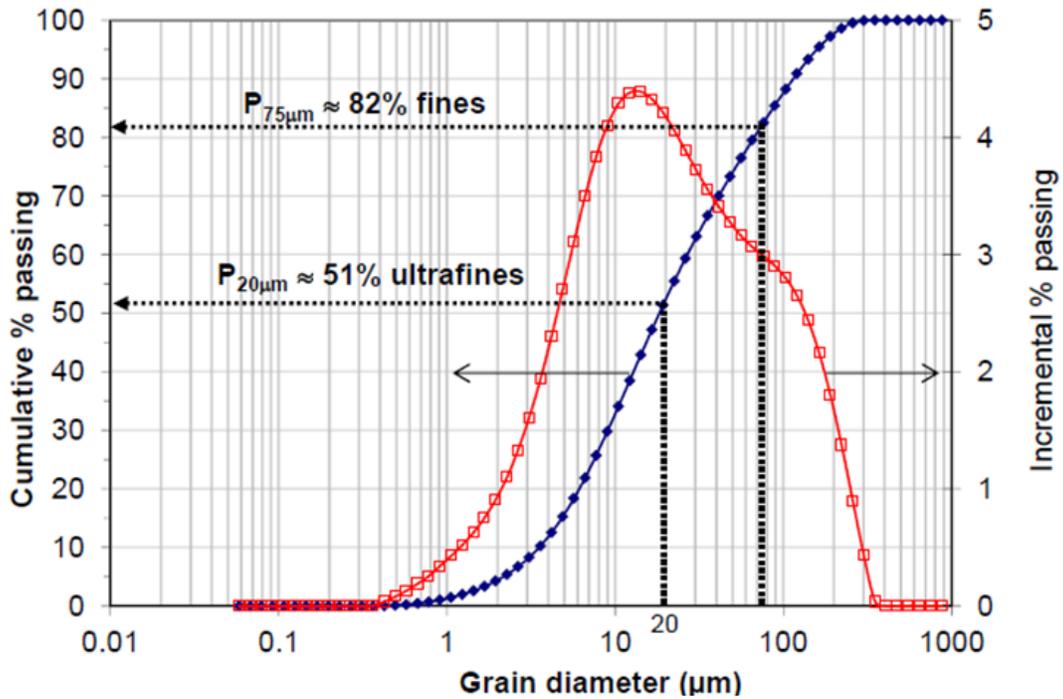


Figure 3 Particle size distribution curve of the Casa Berardi mine tailings

Table 1 Physical properties and mineralogical composition of the three tailings samples

Tailings sample	Physical properties			Mineralogical composition (%)				
	G _s	D ₁₀ (μm)	D ₉₀ (μm)	P ₂₀ μm (%)	Quartz	Pyrite	Chlorite	Muscovite
T1	3.18	4.9	127.0	33	56.2	18.6	5.0	6.2
T2	2.82	3.8	89.3	48	47.8	7.7	22.1	0.7
T3	2.80	3.6	120.7	51	34.8	2.7	12.3	22.7

2.2 Cemented paste backfill mixtures preparation

As previously mentioned, the CPB was obtained by mixing the tailings, binding agent, and water using a Hobart electric mixer (model D 300-1) for 5 to 7 minutes to homogenize the final paste. The different mixtures obtained were poured into plastic moulds (76 mm in diameter and 152 mm in height), then sealed with their lids and stored in a room with a relative humidity of 90% and a temperature of $23 \pm 2^\circ\text{C}$.

Using the three mine tailings samples and varying the type of binding agent and its proportion (binder ratio $B_w = M_{\text{binder}}/M_{\text{dry-tailings}}$), the type of water (tap, lake, sulphated), the mass solid percentage ($C_w = M_{\text{solids}}/M_{\text{bulk}}$), and the curing time, a total of 1,587 specimens were prepared (Table 2).

Table 2 Experimental program for the CPB mixtures preparation

Tailings	Mass solid percentage C_w (%)	Types of binder	Binder ratio B_w (%)	Water quality	Curing time (days)
T1, T2, T3	64 to 88	10GU/90Slag	1 to 9	Tap water Lake water Sulphated water (2500 ppm SO_4^{2-}) Sulphated water (5000 ppm SO_4^{2-})	1 to 213
		20GU/80Slag			
		30GU/70Slag			
		40GU/60Slag			
		40GU/60FA-C			
		50GU/50FA-C			
		60GU/40FA-C			
		57GU/43FA-C			
		70GU/30FA-C			
		100 GU			

2.3 Backfill mixes slump measurement

The fresh paste backfill slump height was determined using the standard Abrams cone (Figure 4), which is the most widely used due to the simplicity of its implementation. This test consists of filling the cone in three layers pounded 25 times by a metal rod, and then the cone is delicately lifted (about 4 seconds) in accordance with ASTM C143 standard. The slump measured was between 6 and 9 in (152 and 229 mm) which corresponds to the typical slump of a paste fill (Landriault et al. 1997).



Figure 4 Slump measurement using the standard Abrams cone method

2.4 Uniaxial compression tests

The uniaxial compression tests were performed using a stiff mechanical press MTS 10/GL with a maximum capacity of 50 kN and run at a constant displacement velocity of 1 mm/min (Figure 5) according to ASTM C39 standard. The tests were carried out in triplicate and a data acquisition system recorded the axial strain and the normal stress applied to the specimens during the test, which allows representing the stress-strain curve and the maximum/peak value which corresponds to the UCS. Note that each UCS value at each curing time is obtained by averaging three values (triplicate).

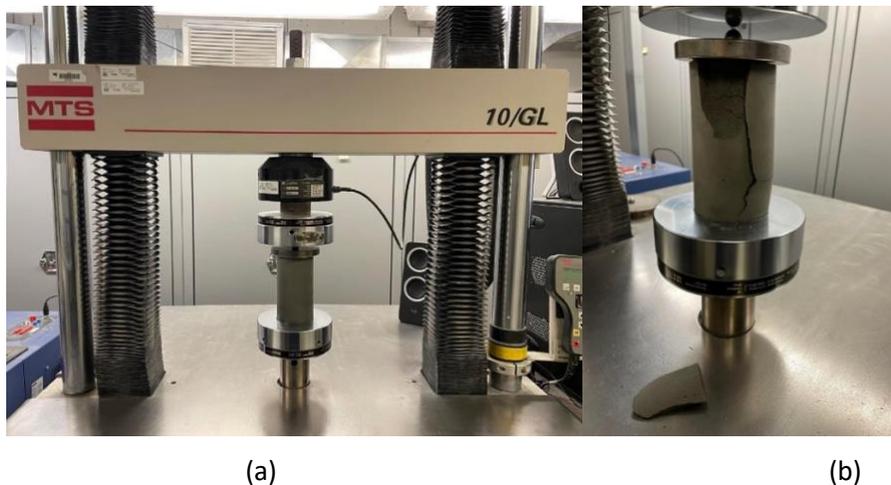


Figure 5 Uniaxial compression test: (a) Stiff mechanical press MTS 10/GL; (b) Broken sample after test

2.5 Prediction methods using machine learning algorithms

The supervised ML process that has been adopted consists of first acquiring the data, processing them (deletion, discretization, normalization, preparation of categorical data if they exist, etc.) and then splitting

the data into two sets. In general, 70% are used for training the models and 30% to testing and validating the models (Nelson & Illingworth 1991; Nguyen et al. 2021). Second, model learning and hyperparameter tuning should be applied. Once the models are properly created and trained, evaluation and validation will be required afterward to select the best-performing one (Mathivet 2021).

In this paper, the data were collected from the results of 1,587 compression tests performed at the Unité de Recherche et de Service en Technologie Minérale Laboratory at the Université du Québec en Abitibi-Témiscamingue (UQAT), of which 17 features were selected as inputs for the models and the target was the UCS. The descriptive statistics of this data is presented in Table 3.

To improve the model learning, the data were scaled using the Robust scaler method by subtracting each value from the median and then dividing by the interquartile range (75% value - 25% value). This method effectively minimizes the effect of outliers compared to other normalization methods. Regarding the modeling, three ML models were chosen considering the dataset size, the type of data, and the data quality (Jakobowicz, 2021) to predict the UCS, namely the GBR, XGBoost regressor (XGBR) and support vector regression (SVR) (Pham et al, 2018; Qi et al, 2018a; Yaseen et al, 2018; Lu et al, 2019; Sun et al, 2020).

Table 3 Descriptive statistics of the data

Parameter	Count	Mean	Std	Min	25%	50%	75%	Max
G_s (-)	1,587	2.88	0.15	2.80	2.80	2.80	2.82	3.18
D_{10} (μm)	1,587	3.84	0.40	3.60	3.60	3.60	3.80	4.60
D_{90} (μm)	1,587	117.01	12.36	89.30	120.70	120.70	120.70	127.00
$P_{20\mu\text{m}}$ (%)	1,587	46.06	6.83	33.00	48.00	50.00	40.00	50.00
% Quartz	1,587	41.41	8.97	34.77	34.77	34.77	47.82	56.15
% Pyrite	1,587	6.87	6.36	2.68	2.68	2.68	7.67	18.60
% Chlorite	1,587	12.33	5.17	5.00	12.33	12.33	12.33	22.08
% Muscovite	1,587	15.63	9.27	0.66	6.20	22.66	22.66	22.66
Slump (inch)	1,587	7.37	0.54	6.25	7.00	7.00	8.00	9.00
Solids concentration (%)	1,587	71.52	2.63	63.90	70.00	72.50	73.23	87.80
GU cement (%)	1,587	39.82	23.87	10.00	20.00	30.00	60.00	100.00
Fly Ash_C (%)	1,587	8.45	18.15	0.00	0.00	0.00	0.00	60.00
Slag (%)	1,587	42.53	39.00	0.00	0.00	70.00	80.00	90.00
Binder ratio B_w (%)	1,587	5.28	1.60	1.00	4.5	4.50	7.00	9.22
Curing time (days)	1,587	44	34	1.00	14.00	28.10	56.00	213
UCS (kPa)	1,587	648.95	646.24	21.00	245.75	456.80	876.60	4,726.00

3 Results and discussion

3.1 Hyperparameters tuning of machine learning models

To avoid overfitting and to find the optimal hyperparameters of the models, a random search method has been used in this study including k -fold cross-validation (k -CV). During the model training, random hyperparameter combinations were selected and then evaluated using cross-validation which consists of randomly dividing the training set into k subsets of which $k-1$ sets are dedicated for training and the remaining set is for validation (Qi et al. 2018a; Lu et al. 2019). The process of cross-validation will be repeated k times, and in this study, k was fixed to be 4 with the number of iterations (n_iter) equal to 10 which gives a total of 40 executions. Table 4 describes the optimal hyperparameters selected for the model learning.

Table 4 Description of the optimal hyperparameters

Model	Hyperparameters
GBR	$learning_rate = 0.16, max_depth = 5, min_samples_split = 4, n_estimators = 613$
XGBR	$Subsample = 1, n_estimators = 800, max_depth = 12, learning_rate = 0.3, gamma = 0.1$
SVR	$C = 10^7, gamma = 10^{-5}$

3.2 Performance evaluation and comparison of machine learning models

The performance evaluation of the models was done based on the linear coefficient of correlation (R), which determines the correlation between the predicted and the actual values. The closer the R-value is to 1, the more accurate the prediction will be. The RMSE measures the prediction error rate on a (N) dataset. These two metrics are defined as follows:

$$R = \frac{\sum_{i=1}^N (y_i^* - \bar{y}^*)(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (y_i^* - \bar{y}^*)^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2}} \quad (1)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y_i^*)^2} \quad (2)$$

where:

y_i^* = predicted values.

y_i = actual values.

\bar{y}_i^* and \bar{y}_i = corresponding averages.

The models are well-trained and their performance increases with the data quality. Figure 6 shows the linear correlation between the predicted UCS using the ML models on the test set and the actual values. Comparing the performance of the models, it can be concluded that the SVR model obtained the worst performance (lowest correlation coefficient $R = 0.95$). However, the GBR and XGBR models exhibit a better fitting (and highest correlation coefficient $R > 0.95$) and can be generalized to be used on new data that they have never encountered before. This can be explained by the fact that algorithms based on DT and the boosting method are usually better performing in the prediction of tabular data. Moreover, the GBR

model has the highest correlation coefficient ($R = 0.99$) due to its optimization algorithm which is based on gradient descent where the errors of previous trees are corrected by the next ones (Mathivet 2021).

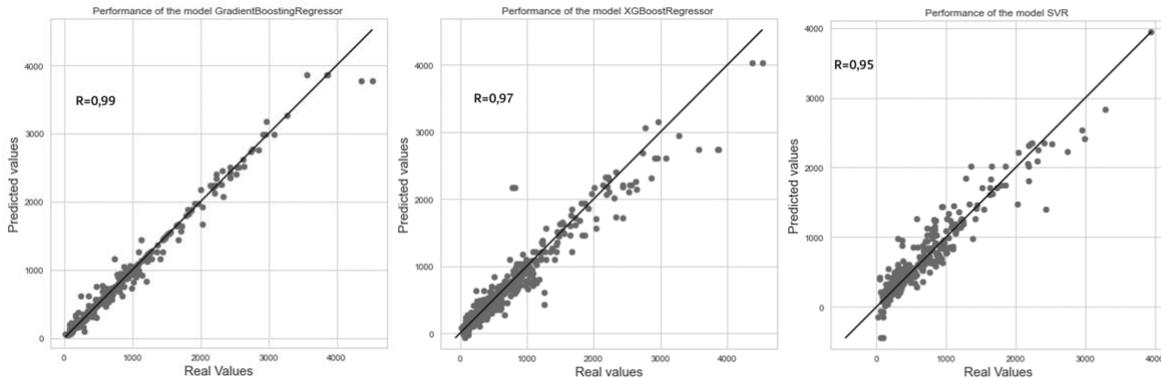


Figure 6 Comparison on the 1:1 line of the predictions obtained by the machine learning models and the actual values

The comparison between the predicted UCS by the models on the test data and the actual values is presented in Figures 7, 8 and 9. Low RMSE values of 0.16 and 0.17 were obtained with the GBR and XGBR models, respectively, while the SVR model is still the least efficient (Table 5).

To validate the evaluation of these models, three CPB mixtures were prepared in the laboratory that do not exist in the dataset with the aim of predicting their UCS values. The prediction results of these three mixtures using the three ML models are presented in Figure 10. As noted on the test dataset, the GBR and XGBR models are the best performers in prediction with a low RMSE error, while the SVR model has a large RMSE error.

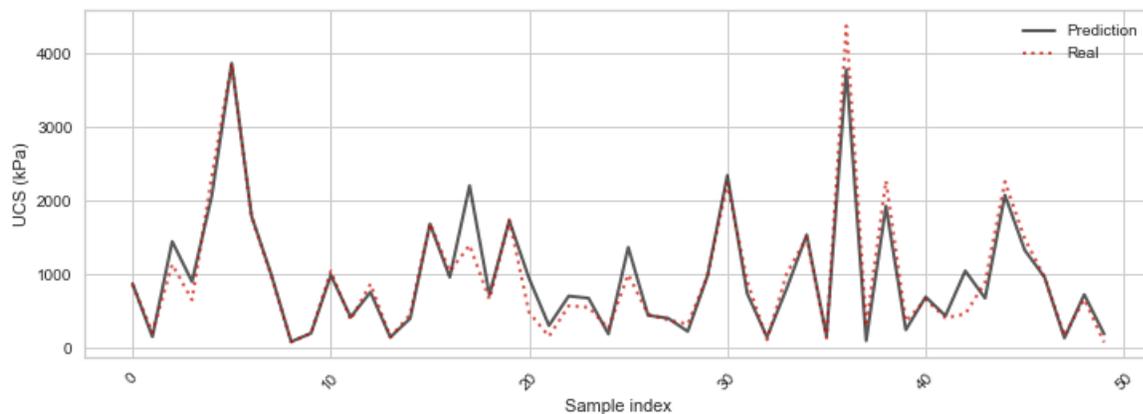


Figure 7 Comparison of actual UCS value and predicted UCS value using the GBR model

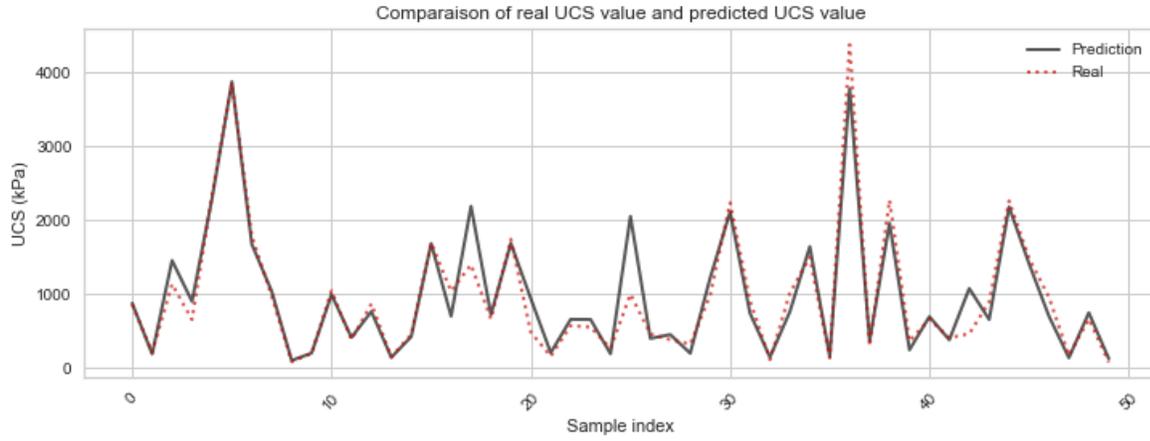


Figure 8 Comparison of actual UCS value and predicted UCS value using the XGBR model

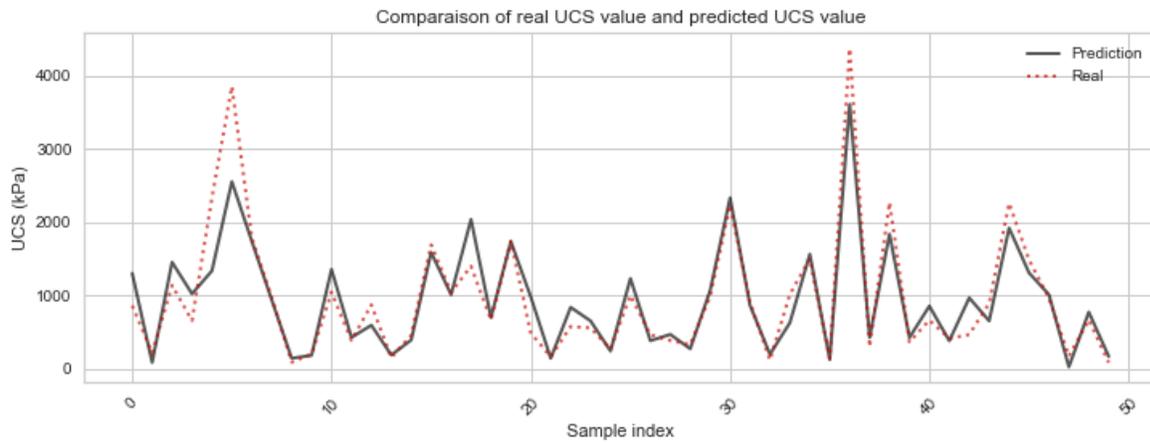


Figure 9 Comparison of real UCS value and predicted UCS value using the SVM model

Table 5 Performance of machine learning models

Parameter	Model (algorithm)		
	SVR	XGBR	GBR
R	0.95	0.97	0.99
RMSE	0.84	0.17	0.16

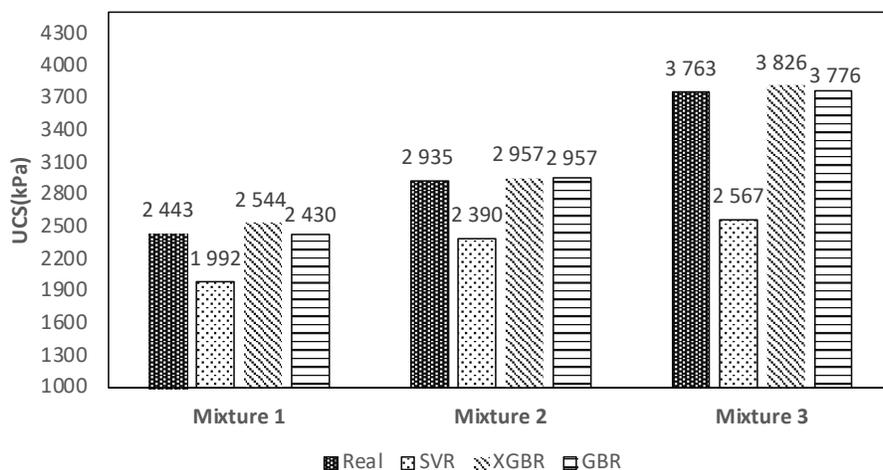


Figure 10 A comparison of the UCS prediction results using the three ML models

4 Conclusion

In this paper, three ML models were trained on a dataset including 1,587 uniaxial compression tests data taking into consideration the physicochemical properties of the tailings, the type and proportion of the binder, the solids mass concentration, the slump of the final paste, the mixing water quality, and the curing time. A pre-processing of data was done before training the models using the robust scaler method for data scaling. A cross-validation has been performed to determine the model hyperparameters and to avoid overfitting and under-fitting.

Evaluation and validation of the model's performance were completed by preparing new CPB mix recipes in the laboratory to determine the corresponding UCS values and to compare them with those obtained using the ML models.

The results of this study show that:

- The interquartile range-based data normalization method is effective in improving model learning and avoiding the effect of outliers.
- Optimisation of the model hyperparameters was done using the random search method with a number of iterations ($n_iter = 10$) followed by a 4-fold cross-validation.
- The best performance (described by the correlation coefficient R and RMSE error) was obtained by using the GBR model.
- Laboratory-scale prediction validation shows that the GBR model can accurately predict the UCS of CPB.

Acknowledgement

The authors would like to thank their university, UQAT and the Government of Canada for their financial support through the Research and Creation Grants – Support for the realisation of short projects (#FIRC/FUQAT 2021-2022), and the NSERC Discovery Grant (#RGPIN-2019-04946), respectively. The

authors would also like to acknowledge the AEM Ltd for their partnership and financial support through the Research Institute of Mines and Environment.

References

- Arioglu, E 1984, 'Design aspects of cemented aggregate fill mixes for tungsten stoping operations', *Mining Science and Technology*, vol. 1, no. 3, pp. 209–214.
- ASTM International 2020, Standard Test Method for Slump of Hydraulic-Cement Concrete (ASTM C143/C143M-20), ASTM International, West Conshohoken.
- ASTM International 2021, Standard Test Method for Compressive Strength of Cylindrical Concrete Specimens (ASTM C39/C39M-21), ASTM International, West Conshohoken.
- Belem, T, Benzaazoua, M & Bussi ere, B 2003, 'Use of paste backfill as ground support. Part I: From its manufacture to its placement underground', *Proceedings International Symposium on Post-mining*, GISOS, Nancy, pp. 5-7.
- Ercikdi, B, Yilmaz, T & K ulekci, G 2014, 'Strength and ultrasonic properties of cemented paste backfill', *Ultrasonics*, vol. 54, no. 1, pp. 195-204.
- Jakobowicz, E 2021, *Python for the Data Scientist: From Language Basics to Machine Learning*, 2nd edn, Dunod, Malakoff Cedex.
- Lamos, A & Clark, I 1989, 'The influence of material composition and sample geometry on the strength of cemented backfill', in FP Hassani, MJ Scoble & TR Yu (eds), *Innovations in Mining Backfill Technology*, AA Balkema Publishers, Brookfield, pp. 89–94.
- Landriault, DA, Verburg, R, Cincilla, W & Welch, D 1997, *Paste Technology for Underground Backfill and Surface Tailings Disposal Applications*, Canadian Institute of Mining and Metallurgy, technical workshop notes, vol. 27, 30 p.
- Lu, X, Zhou, W, Ding, X, Shi, X, Luan, B & Li, M 2019, 'Ensemble learning regression for estimating unconfined compressive strength of cemented paste backfill', *IEEE Access*, vol. 99, pp. 7212572133.
- Mathivet, V 2021, *Machine Learning: Implementation in Python using Scikit-Learn*, Editions ENI, Paris.
- Mitchell, RJ & Wong, BC 1982, 'Behaviour of cemented tailings sands', *Canadian Geotechnical Journal*, vol. 19, no. 3, pp. 289–295.
- Nelson, M & Illingworth, W 1991, *A Practical Guide to Neural Nets*, Addison-Wesley Publishing Co. Inc., Reading.
- Nguyen, QH, Ly, HB, Ho, LS, Al-Ansari, N, Le, HV, Tran, VQ, Prakash, I, Pham, BT 2021, 'Influence of data splitting on performance of machine learning models in prediction of shear strength of soil', *Mathematical Problems in Engineering*, vol. 2021, article ID 4832864.
- Ouattara, D 2017, *Experimental Study of the Rheological and Mechanical Properties of Cemented Paste Mining Backfills Incorporating Superplasticizers*, PhD thesis, Universit  du Qu bec en Abitibi-T miscamingue, Rouyn-Noranda.
- Pham, BT, Hoang, TA, Nguyen, DM & Bui, DT 2018, 'Prediction of shear strength of soft soil using machine learning methods', *Catena*, vol. 166, pp. 181–191.
- Qi, C, Fourie, A & Chen, Q 2018a, 'Neural network and particle swarm optimization for predicting the unconfined compressive strength of cemented paste backfill', *Construction and Building Materials*, vol. 159, pp. 473–478.
- Qi, C, Chen, Q, Fourie, A & Zhang, Q 2018b, 'An intelligent modelling framework for mechanical properties of cemented paste backfill', *Minerals Engineering*, vol. 123, pp. 16–27.
- Sahi, A 2016, *Experimental Validation of an Optimal Binder Selection Model in the Formulation of Cemented mine backfill mix designs*, master's thesis, Polytechnique Montreal.
- Sun, Y, Li, G, Zhang, J, Sun, J & Xu, J 2020, 'Development of an ensemble intelligent model for assessing the strength of cemented paste backfill', *Advances in Civil Engineering*, article ID 1643529.
- Swan, G 1985, 'A new approach to cemented backfill design', *CIM Bulletin*, vol. 78, no. 884, pp. 53–58.
- Yaseen, ZM, Tran, MT, Kim, S, Bakhshpoori, T & Deo, RC 2018, 'Shear strength prediction of steel fiber reinforced concrete beam using hybrid intelligence models: a new approach', *Engineering Structures*, vol. 177, pp. 244–255.
- Yilmaz, T, & Ercikdi, B 2016, 'Predicting the uniaxial compressive strength of cemented paste backfill from ultrasonic pulse velocity test', *Nondestructive Testing and Evaluation*, vol. 31, no. 3, pp. 247–266.
- Yu, T 1989, 'Some factors relating to the stability of consolidated rockfill at Kidd Creek', *Innovations in Mining Backfill Technology*, pp. 279–286.
- Yu Z, Shi X-Z, Chen X, Zhou J, Qi C-C, Chen Q-S & Rao D-J 2021, 'Artificial intelligence model for studying unconfined compressive performance of fiber-reinforced cemented paste backfill', *Transactions of Nonferrous Metals Society of China*, vol. 31, no. 4, pp. 1087–1102.