

Higher National School of Hydraulic

The Library

Digital Repository of ENSH



المدرسة الوطنية العليا للري

المكتبة

المستودع الرقمي للمدرسة العليا للري



The title (العنوان):

Application des Métaheuristiques dans l'optimisation de la formulation de béton compacté au rouleau (BCR) de barrage réservoir..

The paper document Shelf mark (الشفرة) : 8-0004-21

APA Citation (توثيق APA):

Chakali, Youcef. (2021). Application des Métaheuristiques dans l'optimisation de la formulation de béton compacté au rouleau (BCR) de barrage réservoir. [Thèse de doctorat, ENSH].

The digital repository of the Higher National School for Hydraulics "Digital Repository of ENSH" is a platform for valuing the scientific production of the school's teachers and researchers.

Digital Repository of ENSH aims to limit scientific production, whether published or unpublished (theses, pedagogical publications, periodical articles, books...) and broadcasting it online.

Digital Repository of ENSH is built on the open DSpace software platform and is managed by the Library of the National Higher School for Hydraulics. <http://dspace.ensh.dz/jspui/>

المستودع الرقمي للمدرسة الوطنية العليا للري هو منصة خاصة بتقييم الإنتاج العلمي لأساتذة و باحثي المدرسة.

يهدف المستودع الرقمي للمدرسة إلى حصر الإنتاج العلمي سواء كان منشورا أو غير منشور (أطروحات، مطبوعات بيداغوجية، مقالات الدوريات، كتب....) و بثه على الخط.

المستودع الرقمي للمدرسة مبني على المنصة المفتوحة DSpace و يتم إدارته من طرف مديرية المكتبة للمدرسة العليا للري.

كل الحقوق محفوظة للمدرسة الوطنية العليا للري.



ENSH-(n° d'ordre)

**THESE DE DOCTORAT
DE L'ECOLE NATIONALE SUPERIEURE D'HYDRAULIQUE**

Présentée par

Monsieur **CHAKALI Youcef**

pour obtenir le grade de

DOCTEUR DE L'ECOLE NATIONALE SUPERIEURE D'HYDRAULIQUE

Sujet de la thèse :

**Application des Métaheuristiques dans l'optimisation de la formulation
de béton compacté au rouleau (BCR) de barrage réservoir.**

Thèse présentée et soutenue à Blida le 13/09/2021 devant le jury composé de :

M.BENLAOUKLI Bachir	Professeur, ENSH Blida	Président
M.HADJ SADOK Ahmed	Professeur, ENSH Blida	Directeur de thèse
M.TAHLAITI Mahfoud	Enseignant-Chercheur, ICAM Nantes	Co-Directeur de thèse
Mme.ARROUDJ Karima	M.C.A, USTHB Alger	Examinatrice
M.DEBIEB Farid	Professeur, Université Médéa	Examineur
M.HEBBOUCHE Abdelhamid	M.C.A, ENSH Blida	Examineur

Remerciements

Je remercie Monsieur HADJ SADOK Ahmed., Professeur à l'Ecole Nationale Supérieure d'Hydraulique pour avoir accepté de diriger les travaux de ma thèse et pour la confiance qu'il m'a témoignée. Qu'il trouve l'expression de ma profonde reconnaissance pour les orientations, suggestions et conseils qu'il m'a prodigués.

Je tiens également à remercier Docteur TAHLAITI Mahfoud chercheur à l'Institut Catholique des Arts et Métiers pour son aide très fructueuse et de m'avoir accueilli lors de mes séjours à Nantes. Son expérience, m'a été d'une grande importance pour ma formation.

Toute ma gratitude et mes remerciements vont à M. BENLAOUKLI Bachir pour l'honneur qu'il me fait pour présider le jury de ma thèse.

Mes remerciements vont à Mme Dr ARROUDJ Karima, maître de Conférences, membre de jury pour avoir acceptée d'examiner mon travail de thèse. Mes hommages et remerciements vont également à Messieurs, DEBIEB Farid professeur à l'Université de Médéa et LOUKILI Ahmed, professeur à L'Ecole Centrale de Nantes pour avoir acceptés de faire partie de mon jury. De même, je remercie M. HEBBOUCHE Abdelhamid, Maître de Conférences à l'Ecole Nationale Supérieure d'Hydraulique pour avoir accepté d'examiner mon travail.

Je tiens également à remercier M. NACER Tarek Docteur à l'Ecole Nationale Supérieure d'Hydraulique pour son aide très fructueuse. Son expérience dans le domaine de l'intelligence artificiel, m'a été d'une grande importance pour ma formation.

Je suis également reconnaissant mon père M. CHAKALI G., professeur à l'Ecole Nationale Supérieure Agronomique pour le temps qu'il a consacré à la lecture de ma thèse et pour y avoir apporté suggestions et remarques sur sa rédaction.

J'adresse mes remerciements à Monsieur CHAOULI M. Enseignant chercheur à l'université Ziani Achour de Djelfa pour son aide et ses orientations dans le domaine de ma recherche.

Ce travail a trouvé un soutien particulier des services de Cosider laboratoire central des matériaux. Je remercie vivement toutes les personnes qui m'ont offert leur aide au terrain, particulièrement Monsieur le Directeur SITAYEB Saïd et son équipe.

A ces remerciements, je tiens à associer tous les enseignants et l'ensemble du personnel de l'Ecole Nationale Supérieure d'Hydraulique pour leur soutien et leurs encouragements.

Une pensée pour mes parents, mes frères et sœurs et toute ma grande famille pour leur soutien et leurs encouragements constants, j'aimerais leur rendre hommage à travers ce travail.

Mes remerciements vont enfin à tous ceux qui, de près ou de loin, m'ont aidé à la réalisation de cette étude.

Résumé

La formulation du béton compacté au rouleau « BCR » est une opération fondamentale dans la conception d'un barrage aux meilleures conditions technico-économiques. Bien que les méthodes de formulation empiriques ou semi-empiriques actuelles sont utilisées avec succès, la recherche d'une approche plus performante et nécessitant moins d'essais au laboratoire, est d'un intérêt majeur. L'investigation proposée vise à utiliser les techniques issues de l'intelligence artificielle pour optimiser la formulation du BCR de barrage. Les réseaux de neurone artificiels « RNA » ainsi que l'optimisation par les essaims particules « PSO » ont été considérés comme métaheuristiques d'optimisation. Le premier volet de l'étude s'est intéressé à l'optimisation de la compacité du squelette granulaire du BCR qui est une propriété de base. Un programme expérimental a été réalisé au laboratoire sur 174 mélanges granulaires, ayant différents diamètres maximaux et différentes proportions de granulats. Les courbes des mélanges ont été modélisées et leur compacité mesurée expérimentalement. Un modèle hybride RNA-PSO a été développé pour la prédiction de la compacité granulométrique en fonction des paramètres du mélange (D_{max} , d_{10} , d_{30} , d_{50} , d_{60} , d_{80} , % de fillers et les coefficients C_u et C_c). Ce dernier a montré une bonne précision de prédiction. La deuxième partie d'optimisation traite la prédiction de la résistance à la compression « R_c », du rapport Eau/Ciment « E/C » et du dosage en ciment « D_c ». Pour cette étude une base de données de 500 vecteurs de formulations des BCR a été constituée à partir des rapports d'activité de quarte barrages algériens. Après normalisation de la base de données, les paramétrés de formulation les plus significatifs ont été considérés pour le développement de cinq (05) modèles de prédiction. La résistance à la compression est prédite en fonction de diamètre maximum D_{max} , D_c , Dosage en fillers D_f , C , et E/C . Pour la prédiction du rapport E/C et du dosage D_c , deux approches de modélisation ont été considérées faisant sortir 04 modèles en fonction de D_{max} , D_f , C , R_c et le temps de $VeBe$. Les modèles ont été validés expérimentalement au laboratoire et comparés avec la méthode LCPC. Même, avec les quelques différences dans les matériaux et du mode de mise en œuvre du béton, les systèmes développés RNA et/ou RNA-PSO ont montré de très bonnes capacités de prédiction. En fin, une méthodologie globale de la formulation du BCR a été tracée en s'appuyant sur les modèles de prédiction conçus et, pour faciliter son utilisation, des interfaces graphiques ont été mise au point. Ces interfaces offriront à l'utilisateur une exploitation pratique de la méthodologie.

Mots clés : Optimisation, BCR, RNA, PSO, Compacité, Résistance à la compression, Dosage en ciment, Rapport Eau/ciment.

Abstract

The formulation of roller compacted concrete (RCC) is a fundamental operation in the design of a dam at the best technical-economic conditions. Although the current empirical or semi-empirical formulation methods are used with success, the development of a more efficient approach is of major interest. The Artificial Neural Networks (ANN) and Particle Swarm Optimization (PSO) have been proposed as optimization metaheuristics. The research here presented aims using artificial intelligence techniques to optimize the RCC dam's formulation.

The first part of study concerned the granular mixture of RCC's compactness optimization. An experimental program was carried in the laboratory on 174 granular mixtures, with different maximum sizes and aggregates' proportions. The second part deals with the prediction of the compressive strength "Rc", the water/cement ratio "E/C" and the cement rate "Dc". For this study a 500 vectors database of RCC formulations given by laboratory activity reports of 04 dam projects. After the database normalized, the most important parameters of formulation were selected for the development of five (05) prediction models. The compressive strength is predicted as a function of a maximum size of the aggregates (Dmax), cement rate (Dc), limestone filler rate (Df), compactness (C), and water/cement ratio (W/C). For the prediction of E/C ratio and Dc rate, two modelling approaches were considered resulting in 04 model outputs, as a function of Dmax, Df, C, Rc and VeBe time. The models were experimentally validated in the laboratory and compared with the Laboratoire Central des Ponts et Chaussées (LCPC) method. Even with few differences in materials and concrete placement, the developed ANN and/or ANN-PSO systems provided very good predictions.

Finally, a global methodology for RCC formulation was developed, based on the designed prediction models and a graphical interface created to simplify its use and allows to better explore the proposed methodology. a practical exploitation of the methodology.

Key words: Optimization, RCC, ANN, PSO, Compactness, Compressive strength, Cement rate, Water/cement ratio.

ملخص

تعتبر صياغة الخرسانة المضغوطة عملية أساسية في تصميم السد المائي بهدف الحصول على أفضل الخصائص التقنية والاقتصادية. على الرغم من نجاعة طرق الصياغة التجريبية والشبه تجريبية، إلا أن البحث عن سبل أكثر كفاءة يعتبر أمر ذو أهمية بالغة. تهدف الدراسة المقترحة إلى استخدام التقنيات المستمدة من الذكاء الاصطناعي بهدف تحسين صياغة خرسانة السد. ومن هذا المنطلق تم اعتماد الشبكات العصبية الاصطناعية إضافة إلى التحسين بواسطة أسراب الجسيمات.

في الجزء الأول من البحث تم التركيز على دراسة تحسين انضغاط الهيكل الحبيبي والذي يعتبر بدوره عاملاً أساسياً ومهماً في صياغة خرسانة السد. من أجل ذلك تم تنفيذ برنامج تجريبي في المختبر على مائة وأربعة وسبعون (174) خلطة حبيبية ذات أقطار قصوى ونسب ركام مختلفة. وفي الخطوة الموالية تم نمذجة منحنيات المخالط المختلفة وقياس انضغاطها الحبيبي تجريبياً.

هذا وقد تم تطوير نموذج هجين للتنبؤ بانضغاط حجم الجسيمات بالاعتماد على معلمات الخليط (القطر الأقصى للخلطة الحبيبية والأقطار الخاصة بالخليط الحبيبي والتي توافقت بالنسب المئوية 10%، 30%، 50%، 60%، 80% المارة عبر المنخل)، نسبة الحشو الجيري، معامل الانتظام بالإضافة إلى معامل الانحناء.

أما الجزء الثاني من التحسين فقد تناول التنبؤ بكل من قوة الضغط، نسبة الماء/الأسمنت بالإضافة إلى كمية الأسمنت اللازمة للخرسانة. ولذلك، تم إنشاء قاعدة بيانات تضم 500 ناقل مستمد من تقارير الأنشطة المخبرية لأربعة سدود جزائرية. وبعد توحيد قاعدة البيانات، تم اعتماد أهم معاملات الصياغة لتطوير خمسة (05) نماذج تنبؤ.

بالنسبة لمعامل قوة الضغط فتم التنبؤ به اعتماداً على كل من القطر الأقصى للخلطة الحبيبية، كمية الأسمنت، كمية الحشو الجيري، مدة سحق عينات الاختبار ونسبة الماء/الأسمنت.

فيما يخص التنبؤ بكمية الأسمنت ونسبة الماء/الأسمنت، تم اعتماد طريقتين للنمذجة للحصول على أربعة (04) نماذج تنبؤ استناداً إلى كل من قطر الخلطة الحبيبية الأقصى، انضغاط الهيكل الحبيبي، كمية الحشو الجيري، قوة ضغط الخرسانة، عمر سحق عينات الخرسانة ومدة اهتزاز الخلطة الخرسانية.

تم التحقق تجريبياً في المختبر من نجاعة النماذج المطورة ومقارنتها بالنموذج المطور في المختبر الفرنسي المركزي للجسور والطرق.

وبالرغم من وجود بعض الاختلافات في المواد المستعملة وفي طريقة صياغة الخرسانة، إلا أن الأنظمة المطورة أظهرت فاعلية في التنبؤ في توافق عال مع النتائج التجريبية.

في الأخير، تم تحديد منهجية عامة لصياغة الخرسانة المضغوطة استناداً إلى نماذج التنبؤ المطورة. ومن ثمة ومن أجل تسهيل الولوج للسلس لهذه النماذج، تم تطوير واجهات استخدام التي ستوفر بدورها للمستخدم ليونة في الاستعمال.

كلمات مفتاحية: التحسين، الخرسانة المضغوطة، الشبكات العصبية الاصطناعية، التحسين بواسطة أسراب جسيمات، انضغاط الهيكل الحبيبي، قوة الضغط، كمية الأسمنت، نسبة الماء/الأسمنت.

Table des matières

Résumé.....	i
Table des matières.....	iv
Liste des tableaux.....	x
Liste des figures.....	xii
Liste des abréviations.....	xv
Introduction générale.....	1
<i>I. Le béton compacté au rouleau «BCR» : Constituants, propriétés et méthodes de formulations</i>	
I.1 Introduction	5
I.2 Constituants du BCR	5
I.2.1 Les granulats.....	5
I.2.1.1 Gros granulats > 5mm	6
I.2.1.2 Granulats fins < 5 mm	6
I.2.2 Matériaux cimentaires	7
I.2.2.1 Généralités.....	7
I.2.2.2 Le ciment	8
I.2.2.3 Additions minérales.....	10
I.2.3 L'eau de gâchage	12
I.2.4 Adjuvant	12
I.2.4.1 Généralités	12
I.2.4.2 Réducteur d'eau-fluidifiant	13
I.2.4.3 Retardateur et accélérateur de prise	13
I.2.4.4 Agent entraîneur d'air	13
I.3 Propriétés du BCR.....	13
I.3.1 BCR à l'état frais.....	13
I.3.1.1 Maniabilité.....	13
I.3.1.2 Teneur en air	15
I.3.1.3 Ségrégation.....	15
I.3.2 BCR à l'état durci	16
I.3.2.1 Généralités	16
I.3.2.2 Propriétés mécaniques.....	16
I.3.2.2.1 Résistance à la compression.....	16

I.3.2.2.2	Résistance à la flexion	17
I.3.2.2.3	Module élastique.....	17
I.3.2.2.4	Retrait.....	18
I.3.2.2.5	La fatigue	18
I.4	Méthodes de formulation des BCR	19
I.4.1	Introduction.....	19
I.4.2	Domaine d'utilisation	19
I.4.2.1	Pavage	19
I.4.2.2	Barrage	19
I.4.3	Méthodes de formulation	19
I.4.3.1	Méthodes empiriques	20
I.4.3.1.1	Méthode de formulation avec des limites de maniabilité	20
I.4.3.1.1.1	Teneur en eau	20
I.4.3.1.1.2	Teneur en matériaux cimentaires	21
I.4.3.1.1.3	Teneur en agrégats fins	22
I.4.3.1.1.4	Teneur en gros granulats.....	23
I.4.3.1.1.5	Étapes de formulation	24
I.4.3.1.2	Méthode de formulation selon des principes de la géotechnique	26
a)	Teneur en matériaux cimentaires	27
b)	Teneur en granulats fins et grossier.....	27
c)	Teneur en eau.....	27
d)	Étapes de dosage.....	28
I.4.3.2	Méthode semi-empirique.....	30
I.4.3.3	Méthodes théoriques	33
I.4.3.3.1	Le modèle linéaire de compacité (MLC).....	33
I.4.3.3.2	Le modèle d'empilement virtuel	37
I.4.3.3.3	Le modèle de suspension solide (MSS)	39
I.4.3.3.4	Le modèle d'empilement compressible (MEC)	40
I.5	Conclusion	46

CHAPITRE II..... 3

II. Techniques de l'intelligence Artificielle et leur application dans le domaine du béton

II.1	Introduction	48
II.2	Réseau de neurone artificiel (RNA)	48
II.2.1	Introduction et généralités	48
II.2.2	Neurone artificiel (formel)	49

II.2.3	Concepts de base	50
II.2.4	Réseaux de neurones "FEED-FORWARD"	52
II.2.5	Apprentissage	54
II.2.5.1	Algorithme d'apprentissage et principe	55
II.2.5.2	Types d'apprentissage.....	55
II.2.5.2.1	Algorithmes d'apprentissage supervisé et non supervisé.....	55
II.2.5.2.2	Algorithmes d'apprentissage paramétrique et non paramétrique.....	56
II.2.5.2.3	Algorithmes d'apprentissage probabilistes	57
II.2.5.2.4	Algorithmes d'apprentissage univariés et multivariés	57
II.2.6	Avantage et limites des réseaux de neurones artificiels (RNA)	57
II.3	Essaims de particules.....	59
II.3.1	Introduction et historique	59
II.3.2	Définition, inspiration et principe de fonctionnement.....	60
II.4	System hybrid d'essaims de particules réseau de neurones artificiels (RNA-PSO).....	63
II.4.1	Technique d'hybridation	63
II.5	Application de l'intelligence Artificielle dans le domaine du béton.....	65
II.5.1	Introduction	65
II.5.2	Application de l'intelligence artificiel dans la formulation des Bétons	66
II.5.2.1	Application des RNA	66
II.5.2.2	Application du système hybride RNA-PSO	67
II.6	Conclusion.....	68
<i>III. Modélisation et prédiction intelligente de la compacité des mélanges granulaires, applicables aux bétons compactés au rouleau (BCR)</i>		
III.1	Introduction	70
III.2	Matériaux et essais	71
III.2.1	Matériaux utilisés	71
III.2.1.1	Caractérisation.....	72
III.2.1.1.1	Granulométrie	72
III.2.1.1.2	Masses volumiques	74
III.2.1.1.3	Propriétés mécaniques	75
III.2.1.1.4	Propreté.....	76
III.2.2	Compacité des mélanges granulaire	77
III.2.2.1	Méthodes de mesure de la compacité	77
III.2.2.2	Méthode expérimentale utilisée.....	78
III.2.2.2.1	Présentation du dispositif expérimental	78

III.2.2.2.2	Procédure d'essai.....	80
III.2.2.2.3	Optimisation des paramètres d'essai	82
III.2.2.2.4	Compacités des mélanges d'étude.....	85
III.3	Modélisation et prédiction intelligente de la compacité des mélanges.....	86
III.3.1	Modélisation de la courbe granulométrique	86
III.3.2	Constitution de la base de données.....	87
III.3.2.1	Choix des mélanges granulaires	87
III.3.2.2	Mesure de la compacité des mélanges.....	88
III.3.3	Description et développement des modèles intelligents de prédiction de la compacité	91
III.3.3.1	Modèle de Réseau de Neurones Artificiel « RNA ».....	91
III.3.3.1.1	Architecture du RNA	92
III.3.3.2	Modèle hybride RNA-PSO.....	93
III.3.4	Performance et validation des modèles RNA et RNA-PSO.....	95
III.3.5	Analyse paramétrique de sensibilité.....	98
III.4	Conclusion.....	103
<i>IV. Prédiction intelligente des paramètres essentiels de (BCR) à savoir : la résistance à la compression, le rapport E/C et le dosage en ciment</i>		
IV.1	Introduction.....	105
IV.2	Base de données.....	106
IV.2.1	Matériaux et caractéristiques	107
IV.2.1.1	Matériaux utilisés	107
IV.2.1.1.1	Granulats.....	107
IV.2.1.1.1.1	Propriétés des matériaux.....	108
❖	Granulométrie	108
❖	Masse volumique absolue et apparente des matériaux de la base de données	110
❖	L'équivalent de sable ES	111
IV.2.1.1.2	Ciment.....	111
IV.2.1.1.3	Adjuvant.....	112
IV.2.1.1.4	Eau de gâchage	112
IV.2.1.2	Choix des paramètres et limite de la base de données.....	112
IV.3	Prédiction de la résistance à la compression R_c du BCR.....	114
IV.3.1	Modèle "M1" de Réseau de Neurones Artificiel	114
IV.3.1.1	Architecture du RNA.....	114
IV.3.2	Modèle "M2" hybride RNA-PSO	115

IV.3.3	Performance et validation des modèles RNA et RNA-PSO.....	116
IV.3.4	Influence de la résistance du ciment.....	118
IV.4	Prédiction du rapport Eau/Ciment (E/C) et du dosage en ciment (Dc).....	120
IV.4.1	Première approche : Prédiction de C et de E/C individuellement	120
IV.4.1.1	Modèle M3, M4, M5 de prédiction du dosage en ciment et du rapport E/C	120
IV.4.1.1.1	Architecture du modèle M3 de prédiction du dosage en ciment.....	120
IV.4.1.1.2	Modèle M4 de prédiction du dosage en ciment avec une deuxième architecture	121
IV.4.1.1.3	Architecture du modèle M5 de prédiction du rapport E/C.....	122
IV.4.1.2	Performance et validation des modèles M3, M4 et M5	123
IV.4.2	Deuxième approche : Prédiction de C et de E/C simultanément.....	127
IV.4.2.1	Architecture du modèle M6	127
IV.4.2.2	Performance et validation du modèle.....	128
IV.4.3	Validation expérimentale des modèles développés	130
IV.4.3.1	Etude expérimentale	130
IV.4.3.2	Méthode LCPC	134
IV.4.3.3	Résultats et discussion	135
IV.4.3.3.1	Modèle M2, M3, M4 et M5 de la prédiction de la résistance à la compression, le rapport E/C et le dosage en Ciment	135
IV.5	Conclusion	140
V. Méthodologie globale de formulation du BCR		
V.1	Introduction	143
V.2	Phase I : Optimisation du mélange granulaire.....	143
V.2.1	Exemples de simulation de la phase I.....	145
V.2.1.1	Matériaux.....	145
V.2.1.2	Mélanges granulaires.....	146
V.2.1.3	Modélisation des mélanges : Paramètres d'entrée.....	146
V.2.1.4	Prédiction de la compacité "C" avec le modèle "M1" et le développement d'une interface utilisateur	147
V.3	Phase II : Prédiction de la résistance à la compression, le dosage en ciment Dc et du rapport E/C	148
V.3.1	Approche 1 : Prédiction de la résistance à la compression "Rc" (Modèle "M2")	148
V.3.1.1	Paramètres d'entrée.....	148
V.3.1.1.1	Paramètres du mélange granulaire.....	148
V.3.1.1.2	Propriétés du BCR souhaitées	149
V.3.1.2	Exemples de simulation.....	151

V.3.2	Approche 2 : Prédiction du dosage en ciment "Dc" (modèle "M3")	151
V.3.2.1	Paramètres d'entrée.....	151
V.3.2.1.1	Paramètres du mélange granulaire.....	151
V.3.2.1.2	Propriétés du BCR souhaitées	151
V.3.2.2	Exemples de simulation.....	152
V.3.3	Approche 3 : Prédiction du dosage en ciment "Dc" en tenant compte le rapport E/C (modèle "M4").....	153
V.3.3.1	Exemples de simulation.....	153
V.3.4	Approche 4 : Prédiction du rapport Eau/Ciment (modèle "M5").....	154
V.3.4.1	Exemples de simulation.....	155
V.3.5	Approche 5 : Prédiction du dosage en ciment "Dc" et du rapport "E/C" simultanément (Modèle M6).....	155
V.3.5.1	Exemples de simulation.....	156
V.4	Conclusion.....	157
	Conclusions générales	157
	Références bibliographiques	160

Liste des tableaux

Tableau I. 1 Désignation des différents types de ciment en fonction de leur composition [10]	9
Tableau I. 2 Spécification et valeurs garanties en fonction de la classe [10].....	9
Tableau I. 3 Volumes absolus recommandés de gros granulats par unité de volume de BCR	23
Tableau I. 4 Compacités des mélanges binaires. Grains roulés [18].....	42
Tableau I. 5 Compacités des mélanges binaires. Grains concassés [18].....	43
Tableau I. 6 indice de compaction K pour différents procédés de remplissage [18]	44
Tableau I. 7 Compacité mesurée (grains roulés et concassés) et prévision du modèle [18]	45
Tableau III. 1 Récapitulatif des propriétés granulométriques des différentes fractions granulométriques	72
Tableau III. 2 Les masses volumiques des différents granulats utilisés	75
Tableau III. 3 Résultats des coefficients de LA et MDE	76
Tableau III. 4 Résultat d'équivalent des sables	76
Tableau III. 5 Propriété superficielle des graviers	77
Tableau III. 6 Mélanges utilisés pour les essais préliminaires	82
Tableau III. 7 Variation de la compacité en fonction de la charge de compactage	83
Tableau III. 8 Quantité des granulats utilisés	86
Tableau III. 9 Compositions des différents mélanges granulaires de (BCR).....	88
Tableau III. 10 Exemples et intervalles de variation des paramètres des mélanges granulaires	91
Tableau III. 11 Paramètres du modèle PSO-RNA développé	95
Tableau III. 12 Performance du RNA et PSO-RNA modèle	98
Tableau IV. 1 Principales caractéristiques physico-chimiques des fillers calcaires 0/1	107
Tableau IV. 2 Masses volumiques des différents granulats	110
Tableau IV. 3 Résultats des coefficients de LA et MDE	111
Tableau IV. 4 Résultat d'équivalent de sable des barrages de la base de données	111
Tableau IV. 5 Propriétés physico-chimiques des ciments de la base de données	112
Tableau IV. 6 condition d'utilisation de l'eau de gâchage	112
Tableau IV. 7 Exemples et valeurs limites de formulations de BCR de la base de données	114
Tableau IV. 8 Paramètres du RNA-PSO considérés	116
Tableau IV. 9 Performance du RNA et RNA-PSO modèle	118
Tableau IV. 10 Paramètres du RNA considérés pour le modèle M3	121
Tableau IV. 11 Paramètres du RNA considérés pour le modèle M4	122
Tableau IV. 12 Paramètres du RNA considérés pour le modèle M5	123
Tableau IV. 13 Performance des modèles M3, M4 et M5	127
Tableau IV. 14 Paramètres du RNA considérés pour le modèle M6	128
Tableau IV. 15 Performance du modèle M6 de prédiction du "E/C" et du "C"	130
Tableau IV. 16 Caractéristiques physico-chimiques des fillers calcaires 0/1.	131
Tableau IV. 17 Caractéristiques physico-mécaniques des granulats utilisés.	131
Tableau IV. 18 Composition chimique du ciment.	132
Tableau IV. 19 Compositions de BCR étudiées.....	134
Tableau IV. 20 Paramètres statistiques des régressions.	136

Tableau IV. 21 Performances des modèles "M3", "M4", "M5" et du modèle LCPC	140
Tableau V. 1 Exemples sur les pourcentages des fractions granulaires de cinq (05) mélanges granulométriques	146
Tableau V. 2 Exemples sur les paramètres d'entrée choisi pour le modèle "M1"	147
Tableau V. 3 résultats expérimentaux et prédites de la compacité des cinq (05) mélanges granulaires pris en considération sont regroupés dans le Tableau V. 2	148
Tableau V. 4 Exemple de simulation de la Prédiction de la résistance à la compression du BCR par le modèle M2.....	151
Tableau V. 5 Exemple de simulation de la Prédiction du dosage en ciment des BCR par le modèle M4	152
Tableau V. 6 Exemple de Prédiction du dosage en ciment des BCR en tenant compte le rapport EC (Modèle M3).....	154
Tableau V. 7 Exemple de simulation du rapport E/C du BCR à partir de mélange granulaire optimisé et des propriétés souhaitées, par le modèle M5	158
Tableau V. 8 Exemple de simulation du rapport E/C et du dosage en ciment "Dc" du BCR à partir de mélange granulaire optimisé et des propriétés souhaités (Modèle M6)	157

Liste des figures

Figure I. 1 Détermination de la maniabilité à l'aide du test VeBe.....	14
Figure I. 2 Mesure de la masse volumique du BCR.....	15
Figure I. 3 Phénomène de ségrégation sur un mélange BCR réalisé au laboratoire.....	16
Figure I. 4 Relation entre la teneur unitaire en eau et la résistance à la compression du béton.	21
Figure I. 5 Courbes de dosage pour un béton à résistance égale.....	22
Figure I. 6 Volume optimal d'un mortier pour BCR [2].....	23
Figure I. 7 Fuseau granulométrique d'un BCR [28].....	26
Figure I. 8 Relation entre la teneur en eau et la densité d'un mélange BCR [28].....	27
Figure I. 9 Relation type humidité-densité sèche.....	28
Figure I. 10 Courbes Fuller-Thompson modifiées pour différentes tailles d'agrégats [29].....	31
Figure I. 11 Relation expérimentale entre l'ouvrabilité et le rapport du volume et la capacité des vides pour un BCR barrage sans air entrainé [30].....	32
Figure I. 12 Mélange binaire sans interaction avec gros grains dominants [9].....	34
Figure I. 13 Mélange binaire sans interaction avec petit grains dominants [9].....	34
Figure I. 14 Perturbation exercée par les gros et les petits grains sur la classe intermédiaire [9].	35
Figure I. 15 Effet de paroi exercé par un gros grain dans un empilement de grains fins [9].	36
Figure I. 16 Deux classes granulaires avec le même diamètre [33].	37
Figure I. 17 Deux classes granulaires avec le même diamètre [9].	41
Figure I. 18 Mélanges binaires des grains concassés. Compacité en fonction de la proportion de grains fins [9].....	43
Figure I. 19 Mélanges binaires des grains concassés. Compacité en fonction de la proportion de grains fins [9].....	43
Figure II. 1 Représentation (a) d'un réseau neuronal biologique et (b) d'un réseau neuronal artificiel de type Perceptron.....	50
Figure II. 2 Type des fonctions d'activation : (a) Linéaire ; (b) Tan-Sigmoïde ; (c) Log-Sigmoïde....	51
Figure II. 3 Représentation de la structure du modèle de réseau de neurones FEED-FORWARD [59].	52
Figure II. 4 Mécanisme de recherche de l'optimisation par essais de particules.....	62
Figure II. 5 Organigramme du modèle <i>RNA-PSO</i>	64
Figure III. 1 Les granulats utilisés.....	71
Figure III. 2 Courbes granulométriques du filler et des sables.....	73
Figure III. 3 Courbes granulométriques des graviers et ballastes.....	73
Figure III. 4 Essais de mesure des masses volumiques : (a) absolue ; (b) apparente.....	74
Figure III. 5 Essais mécaniques sur granulat : (a) Los Angeles ; (b) Micro Deval.....	75
Figure III. 6 Mesure de la compacité granulaire par différentes méthodes [1].....	77
Figure III. 7 Schéma représentatif du dispositif utilisé pour la mesure de la compacité.....	79
Figure III. 8 Banc d'essai utilisé pour la mesure de la compacité.....	79
Figure III. 9 Etapes de mesure de la compacité : (a) Remplissage du moule, (b) Arasage de la surface du moule, (c) Compactage, (c) Mesure la hauteur h.....	80
Figure III. 10 Mesure de la hauteur (h).....	81

Figure III. 11 Variation de la compacité en fonction de la charge de compactage pour : (a) $D_{max} = 15\text{mm}$; (b) $D_{max} = 25\text{mm}$; (b) $D_{max} = 40\text{mm}$	84
Figure III. 12 Compacité des BCR en fonction de temps de vibration.....	85
Figure III. 13 Stockage des mélanges après l'essai.....	86
Figure III. 14 Modélisation d'une courbe granulométrique d'un mélange.....	87
Figure III. 15 Fuseau granulaire pour mélanges BCR applicables aux routes.....	89
Figure III. 16 Fuseau granulaire pour mélanges BCR applicables aux barrages.....	89
Figure III. 17 Mélanges granulaires étudiés avec des diamètres maximaux $D_{max} 15\text{ mm}$ et 25mm ..	90
Figure III. 18 Mélanges granulaires étudiés avec des diamètres maximaux D_{max} de 40, 50 et 63 mm	90
Figure III. 19 Modèle PSO-RNA pour la prédiction de la compacité.	93
Figure III. 20 Organigramme du modèle PSO-RNA.....	94
Figure III. 21 Variation de l'erreur quadratique en fonction du nombre d'itérations.	95
Figure III. 22 Résultats de régression obtenus par le modèle RNA : (a) Entraînement ; (b) Validation data ; (c) teste ; (d) totale.....	96
Figure III. 23 Résultats de régression obtenus par le modèle PSO-RNA : (a) Validation ; (b) totale.	97
Figure III. 24 Variation de la compacité en fonction de la variation du taux de fine pour : (a) $D_{max} = 15\text{mm}$; (b) $D_{max} = 25\text{mm}$; (c) $D_{max} = 40\text{mm}$ (d) $D_{max} = 50\text{mm}$; (e) $D_{max} = 63\text{mm}$	100
Figure III. 25 Variation de la compacité expérimentale en fonction du D_{max} pour différente taux de fine.....	102
Figure III. 26 Variation de la compacité prédite en fonction du D_{max} pour différente taux de fine	102
Figure IV. 1 Courbe granulométrique laser des fillers calcaires.....	107
Figure IV. 2 Courbes granulométriques (Barrage de Tabelout).....	108
Figure IV. 3 Courbes granulométriques (Barrage de Boussiaba).....	109
Figure IV. 4 Courbes granulométriques (Barrage de Ouljet-Mellegue).....	109
Figure IV. 5 Courbes granulométriques (Barrage de Koudiat Acedoune).....	110
Figure IV. 6 Architecture du modèle de prédiction de la résistance à la compression	115
Figure IV. 7 Variation de l'erreur quadratique en fonction du nombre d'itérations	116
Figure IV. 8 Résultats de régression obtenus par le modèle RNA : (a) Entraînement ; (b) Validation data ; (c) teste ; (d) totale.....	117
Figure IV. 9 Résultats de régression obtenus par le modèle RNA-PSO : (a) Validation ; (b) totale	118
Figure IV. 10 Modèle global de prédiction de la résistance du BCR.....	119
Figure IV. 11 Architecture du modèle M3 de prédiction du dosage en ciment	121
Figure IV. 12 Architecture du modèle M4 de prédiction du dosage en ciment	122
Figure IV. 13 Architecture du modèle M5 de prédiction du rapport E/C	123
Figure IV. 14 Résultats de régression du modèle M3 obtenus par le modèle RNA : (a) Entraînement ; (b) Validation data ; (c) teste ; (d) totale	124
Figure IV. 15 Résultats de régression du modèle M4 obtenus par le modèle RNA : (a) Entraînement ; (b) Validation data ; (c) teste ; (d) totale	125
Figure IV. 16 Résultats de régression du modèle M5 obtenus par le modèle RNA : (a) Entraînement ; (b) Validation data ; (c) teste ; (d) totale	126
Figure IV. 17 Architecture du modèle de prédiction du rapport "E/C" et du dosage ciment "C".	127
Figure IV. 18 Résultats de régression du modèle de prédiction du rapport E/C et du dosage en ciment obtenus par le RNA : (a) Entraînement ; (b) Validation data ; (c) teste ; (d) totale	129
Figure IV. 19 Agrandissement de la courbe de régression totale du modèle M7 de prédiction du E/C et du C : (a) rapport E/C ; (b) Ciment C.....	129

Figure IV. 20 Courbes granulométriques des mélanges granulaires.....	131
Figure IV. 21 Photos de l'étude expérimentale : (a) Vérification de l'absence d'affaissement et calcul du temps de VEBE ; (b) Spécimens de RCC ; (c) Conditionnement des spécimens avant l'essai ; (d) Essai de résistance à la compression.	133
Figure IV. 22 Régression linéaire entre les résultats expérimentaux et ceux simulés le RNA-PSO..	135
Figure IV. 23 Régression linéaire entre les résultats expérimentaux et ceux simulés par la méthode LCPC.....	136
Figure IV. 24 Régression linéaire entre : (a) le ciment expérimental et prédit par le LCPC ; (b) le rapport E/C expérimentale et prédit par le LCPC.....	138
Figure IV. 25 Régression linéaire entre le ciment expérimental et prédit par le RNA (modèle "M3")	138
Figure IV. 26 Régression linéaire entre le ciment expérimental et prédit par le RNA ("M4")	139
Figure IV. 27 Régression linéaire entre le rapport E/C expérimental et prédit par le RNA ("M5") ..	139
Figure V. 1 Organigramme de la méthodologie de prédiction de la compacité granulométrique.....	144
Figure V. 2 Courbes granulométriques des différents matériaux utilisés dans le modèle de prédiction de la compacité.....	145
Figure V. 3 Exemple d'un mélange granulométrique utilisé pour barrage en BCR	145
Figure V. 4 Exemple d'un mélange granulométrique utilisé pour route en BCR	146
Figure V. 5 Interface utilisateur du modèle "M1" de prédiction de la compacité granulométrique ...	147
Figure V. 6 Interface utilisateur du modèle "M2" de prédiction de la résistance à la compression du BCR	149
Figure V. 7 Organigramme globale de la méthodologie de prédiction des paramètres importants du BCR.....	150
Figure V. 8 Interface utilisateur du modèle "M4" de prédiction du dosage en ciment du BCR.....	152
Figure V. 9 Interface utilisateur du modèle "M2" de prédiction du dosage en ciment du BCR en tenant compte le rapport E/C.....	153
Figure V. 10 Interface utilisateur du modèle "M5" de prédiction du rapport E/C du BCR.....	154
Figure V. 11 Interface utilisateur du modèle "M6" de prédiction de "Dc" et "E/C" simultanément..	156

Liste des abréviations

ACO	Algorithme de colonies de fourmis
a_{ij}	Effet de paroi
b	Le seuil d'activation (biais) du neurone
b_{ij}	Effet de desserrement
BP	Rétropropagation
β	Compacité virtuelle d'une classe de grain.
C	Compacité du mélange granulaire
Cc	Coefficient de courbure
Cu	Coefficient de Hazen
d	Taille des tamis (mm)
dk	Valeur de sortie désirée du réseau de neurones
Dmax	Diamètre maximale des granulats (mm)
d(t)	Paramètre reflétant l'âge du béton
E	Erreur de calculé du réseau de neurones
E/C	Rapport Eau/ciment
E / L	Rapport eau / liant
EMP	Modèle d'empilement compressible
Esp	Équivalent de sable
FL	Logique floue
$f(N)$	Phénomène de la fatigue
GA	L'algorithme génétique
HS	Recherche d'harmonie
IA	Intelligence artificielle
K	Indice de serrage
Kg	Constante reliée au mélange granulaire utilisé
La	Coefficient Los Angeles
LCPC	Laboratoire des Pont et des Chaussées
MAE	Erreur absolue moyenne
MAPE	Erreur absolue moyenne en pourcentage
M_{DE}	Coefficient Micro-Deval
MEC	Modèle d'empilement compressible
MF	Module de finesse
MLC	Modèle linéaire de compacité
MSE	Erreur quadratique moyenne
MSS	Le modèle de suspension solide
MR	Module de rupture du béton
N	Le nombre de cycles
p	Pourcentage des passants (%) des particules dans un tamis de grosseur d.
P/C	Pouzzolane/ciment
P_s	Propreté superficielle du sable
PSO	Optimisation par essaims de particules
P_T	Volume de pate
R	Coefficient de corrélation
R²	Coefficient de détermination
R_c	Résistance à la compression du béton
RMSE	Racine de Moyenne de l'erreur carrée

RNA	Réseaux de Neurones Artificiels
SA	Recuit simulé
SP	Super plastifiant
T	Température de durcissement
V_A	Volume de l'air
V_C	Volume du ciment
V_{CA}	Volume des gros granulats
V_{FA}	Volume d'agrégat fin
V_{MT}	Volume total de mortier
V_p	Volume de pouzzolane
V_s	Volume des solides mélange granulaire
V_T	Volume total mélange granulaire
V_V	Volume des vides du squelette granulaire compacté
V_W	Volume d'eau d'essai
w	Poids synaptique d'un neurone
x_n	La valeur normalisée du réseau de neurones
Y	Proportions volumiques d'une classe granulaire
Zk	Représente la valeur calculée du réseau de neurones
α_i	Compacité expérimentale de la classe "i" prise isolément.
Y	Compacité virtuelle d'un mélange
σ_a	Amplitude de contrainte
Ø	Partiels d'une classe de grain dans une 'unité de volume de mélange
η_r[*]	Viscosité relative de référence
ρ_{abs}	Masse volumique absolue
ρ_{app}	Masse volumique apparente

Introduction générale

Introduction générale

La stabilité et la durabilité des barrages en béton compacté au rouleau (BCR) dépendent particulièrement des propriétés du BCR lui-même (Résistances mécaniques, perméabilité, propriétés de transfert thermique, résistance au gel...). La maîtrise de ces propriétés est liée, non seulement à la qualité des matériaux constitutifs du béton, mais aussi à sa formulation (quantités des différents matériaux).

Généralement le problème de formulation du béton, qui est un matériau hétérogène, se résume à la mise en œuvre d'une relation mathématique entre deux groupes de paramètres : les propriétés désirées (ouvrabilité, résistance, perméabilité, ...) et les caractéristiques ainsi que les quantités des constituants du béton (ciment, granulats, eau, adjuvant). Le nombre important et les interactions entre ces paramètres, augmentent considérablement la difficulté du problème. La plupart des méthodes de formulation généralement utilisées pour le béton conventionnel ne sont pas directement applicables au BCR. Plusieurs méthodes de formulation de mélanges de BCR ont été développées avec succès en utilisant différentes approches. Les méthodes proposées sont basées sur des approches empiriques ou semi-empiriques qui requièrent la réalisation d'un grand nombre de gâchées d'essais afin d'obtenir le mélange aux proportions optimales. Les méthodes empiriques sont considérées dans la première catégorie pour réaliser les mélanges BCR [1]. Cette approche est généralement basée sur des gâchages d'essais dépassant souvent 25 gâchées au laboratoire pour avoir un mélange avec les caractéristiques souhaitées. La réalisation d'autres combinaisons d'essais sur le site est parfois nécessaire pour l'ajustement de la maniabilité du BCR [2]. Ce type de formulation est efficace et simple à utiliser mais nécessite du temps et de l'énergie pour corriger et adopter la formulation recherchée. Le second type se base sur des formules empiriques et des données expérimentales, avec comme principe général le calcul du volume de la pâte par rapport au volume des vides intergranulaires restant après le compactage du squelette granulaire, avec toutefois la nécessité de confectionner quelques gâchées d'essais au laboratoire. Dans le cas où le volume de la pâte choisi est inférieur au volume des vides intergranulaires, cela conduit à la réduction des propriétés mécaniques et de l'étanchéité du béton. Par contre, avec un surdosage de la pâte, le problème d'accroissement de la chaleur d'hydratation surgit et le coût de réalisation devient plus conséquent. Enfin, les méthodes théoriques [3] récemment développées œuvrant à l'optimisation du mélange granulaire et de la pâte de liant (Modèle d'empilement granulaire, méthode LCPC ...) restent efficaces mais impliquent une caractérisation expérimentale contraignante des différents

Introduction générale

matériaux constitutifs du BCR. En effet, cette approche implique un grand nombre de paramètres, influençant le béton aux états frais et durci.

Récemment, l'introduction de l'optimisation par les métaheuristiques dans le domaine du génie civil a donné des résultats assez prometteurs. Les métaheuristiques sont des méthodes d'optimisation basées, sur des théories inspirées, par des analogies avec les sciences de la physique, de la biologie ainsi que de l'éthologie [4–6]. Les Réseaux de Neurones (RNA), les Algorithmes Génétiques (AG) et les algorithmes de colonies de fourmis (ACF) sont parmi les méthodes les plus connues et sont couramment utilisées. Les métaheuristiques permettent de résoudre des problèmes dans divers domaines, notamment en génie civil [7]. En effet, les RNA ont été largement utilisés dans la prédiction de plusieurs paramètres du béton tel que la maniabilité [8], la résistance à la compression [9], les paramètres de formulation [10] et même le degré d'hydratation de la pâte de ciment [11]. L'application de ces méthodes, par rapport aux méthodes conventionnelles, permet une optimisation des problèmes complexes, discrets ou continus.

La présente investigation, propose l'utilisation de métaheuristiques (Réseaux de Neurones Artificiels « RNA », Algorithme des essaims particules « PSO ») pour l'optimisation globale de la formulation des BCR utilisables dans la construction de barrages, en s'appuyant sur une base de données de BCR (formulations-caractéristiques). La base de données dérive des résultats de rapports d'activité de laboratoire de barrages algériens en BCR (Cas du barrage de Koudiat-Acerdoun de la wilaya de Bouira réalisé par le bureau d'étude français RAZEL, cas du barrage de Tabellout de la wilaya de Jijel réalisé par le bureau d'étude français RAZEL, cas du barrage de Ouljet-Mellegue dans la wilaya de Tébessa réalisé par le groupe COSIDER, cas du barrage de Boussiaba de la wilaya de JIJEL). Pour des raisons de fiabilité, la base données a été traitée et normalisée pour répondre aux exigences des entrées de base, lors de la modélisation intelligente par des métaheuristiques.

Le deuxième volet de la recherche repose sur la mise en place d'une étude expérimentale pour la confection de bétons compactés au rouleau (BCR) pour se rapprocher au mieux des conditions réelles de mise en œuvre des BCR de barrages. L'objectif de cette étude et de rapprocher au mieux des conditions réelles de mise en œuvre des BCR de barrages (Confection, conservation et mesure des caractéristiques essentielles du BCR). Par ailleurs, elle permet la réalisation d'un programme expérimental basé sur différentes formulations de BCR afin de

Introduction générale

valider les différents modèles d'optimisation développés. Une fois les différents modèles validés, ils seront regroupés dans une méthodologie globale de formulation du BCR, laquelle sera valorisée dans un logiciel de calcul avec interface utilisateur. Ainsi, le travail effectué dans le cadre de la présente thèse s'est organisé en cinq (05) chapitres répartis comme suit :

Le premier chapitre traite d'une synthèse bibliographique sur le béton compacté au rouleau « BCR », sa constitution, ses propriétés et les méthodes de formulations utilisées.

Le second chapitre porte sur l'analyse des données et sur les techniques d'intelligence artificielle et leurs applications dans le domaine du génie civil d'une manière générale et particulièrement sur les matériaux reliés au béton.

Le troisième chapitre s'est consacré à la mise en place d'un modèle métaheuristique pour la prédiction de la compacité des mélanges granulaires utilisables aux BCR, en se basant principalement sur des propriétés géométriques basiques des mélanges, issus d'une modélisation pertinente. Les réseaux de neurones artificiels ainsi que les Particules Swarm Optimisation « PSO », sont utilisés comme algorithmes d'optimisation.

Sur la base des données recueillies des quatre barrages d'étude, le quatrième chapitre s'est réservé au développement d'une multitude de modèles RNA et hybride RNA-PSO pour la prédiction de la résistance à la compression, le rapport E/C et le dosage en ciment D_c du BCR. Ce travail a été suivi par la réalisation d'un programme expérimental sur des BCR au laboratoire afin de valider les différents modèles.

Enfin, le cinquième chapitre de l'investigation porte sur la mise en place d'interfaces pour faciliter à l'utilisateur l'exploitation des modèles développés dans une méthodologie globale de formulation du BCR. Ces interfaces ont été développées à l'aide de Matlab Designer. La dite méthodologie globale, permet à l'utilisateur de prédire et d'optimiser tous les paramètres essentiels du BCR à savoir : la compacité du mélange, le rapport E/C, le dosage en ciment, la résistance à la compression en fonction des différentes propriétés des matériaux constitutifs du BCR.

CHAPITRE I

*Le béton compacté au rouleau «BCR»:
Constituants, propriétés et méthodes
de formulations*

1.1 Introduction

Récemment, le béton compacté au rouleau « BCR » est de plus en plus utilisé dans la construction de barrages et de chaussées du fait de ses caractéristiques techniques avantageuses et de son faible coût de production. Les BCR pour barrages, confectionnés à partir d'un mélange granulaire formé de sable et de graviers de diverses dimensions pouvant atteindre les 100 mm de diamètre, sont aussi caractérisés par un faible dosage en ciment afin de limiter la fissuration due au retrait thermique. Pour augmenter la compacité du mélange granulaire, des fillers sont additionnées. Ces derniers, peuvent être pouzzolaniques ou inertes tel que les fillers calcaires qui sont très utilisés de par leur disponibilité. En vue des propriétés spécifiques de (BCR) par rapport au (BCV), plusieurs méthodologies théoriques et expérimentales ont été développées pour optimiser les BCR, regroupées dans diverses catégories : théoriques, semi-empiriques et empiriques.

1.2 Constituants du BCR

1.2.1 Les granulats

D'après Harrington et al [12], les granulats dans le BCR représentent 60 à 85 % du volume total du mélange. Plusieurs propriétés du BCR tel que la maniabilité, la densité du mélange, la résistance à la compression et à la traction, les propriétés thermiques à court et à long terme sont directement liées aux propriétés et aux proportions des granulats utilisées dans le mélange.

Comme dans le cas du béton conventionnel, la qualité et les propriétés des granulats utilisés dans le mélange BCR doivent être contrôlées durant la période de construction. Des essais peuvent être effectués pour confirmer la cohérence de la granulométrie des granulats ainsi que des propriétés telles que l'absorption, la densité spécifique, l'indice de plasticité, la résistance à l'abrasion, la réactivité alcali-silice, ... [13]. Par rapport au béton conventionnel, le BCR diffère par ses exigences granulométriques [14]. La différence de granulométrie vient de la nécessité de consolider le squelette des granulats du BCR sous l'effet des efforts de compactage mécanique par rouleau compacteur [15]. La granulométrie des agrégats fins et grossiers doit être soigneusement sélectionnée pour garantir une maniabilité, une compactibilité et une finition de surface adéquates [16]. La bonne sélection de granulats et de leurs granulométries réduit le potentiel de ségrégation et améliore la résistance et la durabilité du BCR [13]. Le choix

des granulats aura également une incidence sur les besoins en eau et la quantité de matériaux cimentaires nécessaires.

Les pratiques de sélection et de mélange des granulats peuvent varier en fonction des pratiques locales, des spécifications de construction, de la classe d'exposition, de leur disponibilité, ainsi que de la commodité du producteur de béton et du constructeur et de l'environnement économique [12]. Des granulats concassés ou non concassés peuvent être utilisés dans les mélanges de BCR, en fonction de la disponibilité.

Un mélange de granulats dense et bien calibré est le plus recherché. Dans la plupart des cas, les produits fins et grossiers sont mélangés à des proportions étudiées pour produire un mélange granulaire de bonne propriétés de compaction [17].

1.2.1.1 Gros granulats > 5mm

Le facteur le plus important à prendre en compte lors du choix de la source, de la forme et de la granulométrie d'un granulat grossier est d'éviter la ségrégation du béton. Quelles que soient les propriétés théoriques d'un BCR, si ce béton se ségrège lorsqu'il est transporté, étalé et mis en œuvre, les performances in-situ seront amoindries. Afin d'éviter la ségrégation, il a été constaté qu'un granulat bien calibré, avec une faible quantité de la fraction la plus grossière, est plus satisfaisant. La taille maximale des granulats peut avoir un effet très important sur la ségrégation. En général, plus la taille maximale est petite, moins la tendance à la ségrégation est importante. Il a été constaté qu'une augmentation de la proportion de granulats fins dans la granulométrie totale peut réduire la tendance à la ségrégation [18]. La taille maximale la plus populaire est de 75 à 80 mm [19], bien qu'il semble y avoir une tendance vers des tailles plus petites en raison du problème de ségrégation.

1.2.1.2 Granulats fins < 5 mm

Dans un BCR, l'importance de la fraction des grains < 5 mm est bien notée dans le remplissage des vides intergranulaire. Cette fraction dans un BCR peut atteindre un pourcentage de 40% par rapport au pourcentage totale des granulats dans le but de l'amélioration du compactage. Généralement, cette fraction est obtenue à partir du concassage et de broyage des roches. D'après la norme XP P 18-540, cette fraction de grain contient trois sous fractions de grain :

- Les fillers : cette fraction contient les particules ayant un diamètre < 2 mm avec au moins de 70% de passant à 0,063mm

- Les sablons : cette fraction de grain comporte les granulats de diamètre $\leq 1\text{mm}$ avec au moins de 70% de passant à 0,063mm

Et enfin la partie des sables qu'il contient les particules de diamètre compris entre 1 et 6,3 mm.

Il a été observé qu'avec une teneur en éléments fins totale (liant compris) de l'ordre de 8 à 15 %, on obtient un bon comportement du BCR au compactage [20]. Dans certains cas, la totalité de ces éléments fins a une origine artificielle (ciment + additions). Toutefois, dans le cas général, une partie des éléments fins provient des granulats, notamment des sables ; ils ont alors souvent des propriétés actives, favorables ou non. L'obtention d'une quantité d'éléments fins naturels appropriée peut être coûteuse (unité de dé-fillerisations). La teneur en éléments fins peut être un paramètre déterminant dans le choix des sables.

Les essais de laboratoire ont pour objectif de définir la compatibilité relative entre les liants et les éléments fins utilisés. Certains d'entre eux peuvent avoir des propriétés pouzzolaniques autorisant une réduction de la teneur en liant. Dans d'autres cas, la présence d'éléments fins plastiques, l'existence d'éléments fins présentant des réactions chimiques défavorables avec le liant, et le non-lavage des granulats peuvent conduire à réduire sensiblement les résistances en traction et au cisaillement, du fait de la rupture de l'interface pâte/granulats et de l'enrobage des éléments fins. Dans le cas particulier où les éléments fins comprennent des matériaux gonflants, difficiles à mélanger au liant (formation de boulettes) et à transformer et à stabiliser par les éléments actifs, leurs variations dimensionnelles peuvent altérer gravement la tenue au long terme des parements. C'est pourquoi l'emploi de ce type d'élément fin n'est envisageable que pour des ouvrages particuliers ne mobilisant pas la résistance à la traction et intéressant faiblement la résistance au cisaillement. Il est donc indispensable de caractériser la nature et l'activité des éléments fins, le type et la quantité de liant éventuellement nécessaire pour la stabilité et la pérennité du matériau résultant.

I.2.2 Matériaux cimentaires

I.2.2.1 Généralités

Le BCR peut être fabriqué avec l'un des types de ciment de base ou, plus généralement, avec une combinaison de ciment et une addition minérale. Il est bien connu que la grande majorité des mélanges de BCR contient des additions minérales (généralement du laitier de haut fourneau granulé, des cendres volantes, de la pouzzolane naturelle, de la farine de roche et du calcaire). L'utilisation d'additions minérales a les effets souhaitables de réduire la teneur en ciment

Portland, ce qui permet généralement d'abaisser les coûts, de réduire la chaleur d'hydratation et de donner un développement plus lent de la résistance qui peut réduire les contraintes thermiques.

1.2.2.2 Le ciment

le ciment prend aussi le nom de liants hydraulique à cause de la propriété de s'hydrater dans l'eau, cette hydratation transforme la pâte liante, qui a une consistance de départ plus au moins fluide, en un solide pratiquement insoluble dans l'eau.

Actuellement, les composés de base de ciments sont les silicates et l'aluminates de calcium résultant de la combinaison de la chaux (CaO) avec la silice (SiO₂), l'alumine (Al₂O₃) et l'oxyde de fer (Fe₂O₃). La chaux est apportée par des roches calcaires, l'alumine, la silice et l'oxyde de fer par des argiles.

Le Calcaire et l'argile sont extraits des carrières, puis concassés, homogénéisés, portés à haute température (1450 °C) dans un four. Le produit obtenu après refroidissement rapide est le clinker Portland. En plus une quantité de gypse est ajoutée et finement broyée de manière à obtenir une poudre dont la masse volumique absolue comprise entre 3 et 3,2 g/cm³.

La classification des ciments est faite en fonction de leur composition, cinq types principaux selon la norme NF P 15-301 et EN 197-1 ont été définis. Ils sont notés CEM et numérotés de 1 à 5 en chiffres romains dans leur notation européenne :

CEM I : ciment Portland (CPA dans l'ancienne notation française), CEM II : ciment Portland composé (CPJ), CEM III : ciment de haut fourneau (CHF), CEM IV : ciment pouzzolanique (CPZ), CEM V : ciment composé (ou ciment au laitier et aux cendres : CLC). Le Tableau I. 1 illustre les désignations des différents types de ciment en fonction de leur composition

Tableau I. 1 Désignation des différents types de ciment en fonction de leur composition [10]

Classe	Résistance à la compression (MPa) EN 196-1 (et P 15-301)				Retrait à 28 jours (1) P 15-433 ($\mu\text{m/m}$)	Début de prise EN 196-3 (min)	Stabilité EN 196-3 (mm)
	au jeune âge		à 28 jours				
	2 jours	7 jours	mini	maxi			
32,5 N		$\geq 16,0$ 14	$\geq 32,5$ 30	$\leq 52,5$	≤ 800	≥ 75 (90) 60 (90)	≤ 10
32,5 R	≥ 10 (13,5) 8 (12)		$\geq 32,5$ 30	$\leq 52,5$	$\leq 1\ 000$	≥ 75 (90) 60 (90)	≤ 10
42,5 N	≥ 10 (12,5) 10		$\geq 42,5$ 40	$\leq 62,5$	$\leq 1\ 000$	≥ 60 50 (60)	≤ 10
42,5 R	≥ 20 18		$\geq 42,5$ 40	$\leq 62,5$	$\leq 1\ 000$	≥ 60 50 (60)	≤ 10
52,5 N	≥ 20 18		$\geq 52,5$ 50			≥ 45 (60) 40 (60)	≤ 10
52,5 R	≥ 30 28		$\geq 52,5$ 50			≥ 45 (60) 40 (60)	≤ 10

Le ciment est aussi classé selon leur résistance à 28 jours. Il existe trois type de classes: " 32,5" ; " 42,5" et "52,5". Chaque classe se divise en deux sous-classes "N" et "R". les différentes propriété des sous classe sont illustrées dans le Tableau I. 2

Tableau I. 2 Spécification et valeurs garanties en fonction de la classe [10]

	Cim. Portland	Ciment Portland composé		Ciment de haut fourneau			Ciment pouzzolanique		Ciment composé	
	CEM I	CEM II/A	CEM II/B	CEM III/A	CEM III/B	CEM III/C	CEM IV/A	CEM IV/B	CEM V/A	CEM V/B
Clinker (K)	$\geq 95\ %$	$\geq 80\ %$ $\leq 94\ %$	$\geq 65\ %$ $\leq 79\ %$	$\geq 35\ %$ $\leq 64\ %$	$\geq 20\ %$ $\leq 34\ %$	$\geq 5\ %$ $\leq 19\ %$	$\geq 65\ %$ $\leq 89\ %$	$\geq 45\ %$ $\leq 64\ %$	$\geq 40\ %$ $\leq 64\ %$	$\geq 20\ %$ $\leq 38\ %$
Laitier (S)	*	$6\ % \leq$	$21\ % \leq$	$\geq 36\ %$ $\leq 65\ %$	$\geq 66\ %$ $\leq 80\ %$	$\geq 81\ %$ $\leq 95\ %$	*	*	$\geq 18\ %$ $\leq 30\ %$	$\geq 31\ %$ $\leq 50\ %$
Pouzzolanes (P ou Q)	*	total	total	*	*	*	$11\ % \leq$	$36\ % \leq$	$18\ % \leq$	$31\ % \leq$
Cendres siliceuses (V)	*	$\leq 20\ %$	$\leq 35\ %$	*	*	*	total $\leq 35\ %$	total $\leq 55\ %$	total $\leq 30\ %$	total $\leq 50\ %$
Fumée de silice (D)	*	(fumée)	(fumée)	*	*	*	(fumée $\leq 10\ %$)	(fumée $\leq 10\ %$)	*	*
Cendres calcaïques (W)	*	de	de	*	*	*	*	*	*	*
Schistes (T)	*	silice	silice	*	*	*	*	*	*	*
Calcaires (L ou LL)	*	$\leq 10\ %$	$\leq 10\ %$	*	*	*	*	*	*	*
Fillers	*	*	*	*	*	*	*	*	*	*

Le BCR est réalisé à partir de n'importe quel type de ciment de base. Pour les barrages BCR, des ciments générant moins de chaleur d'hydratation que le ciment Portland ordinaire (de type CEM I), peuvent être bénéfiques. Ils comprennent le type CEM II (Chaleur modérée), le type IV et V (ciment Portland Pozzolaniques) et le type III (Ciment de haut fourneau). Le développement de la résistance de ces ciments à faible chaleur d'hydratation est généralement plus lent que pour le ciment Portland ordinaire au jeune âge. À des âges avancés, ces ciments produisent généralement des résistances plus élevées que les ciments Portland ordinaires de type CEM I.

I.2.2.3 Additions minérales

Les additions minérales sont des matériaux siliceux ou calcaire finement broyés ajoutés au ciment. L'utilisation de matériaux pouzzolaniques dans les bétons massifs est une pratique ancienne et renommée, avec un taux d'utilisation moyen autour de 15 et 25%. L'avènement des BCR a conduit à l'utilisation de teneurs plus élevées en additions minérales.

Certaines additions minérales peuvent présenter une activité pouzzolanique (cendres volantes, pouzzolane naturelle, ...), d'autres ont des propriétés hydrauliques latentes (laitier de haut fourneau broyé), tandis que d'autres regroupe les deux propriétés (Cendres volantes à haute teneur en chaux). Si aucune autre source d'adjuvants minéraux n'est disponible, il est possible d'obtenir une certaine activité pouzzolanique par l'utilisation d'une charge siliceuse par le concassage des roches avec une certaine quantité et condition minéralogique de matrice siliceuse. Même si ces deux derniers matériaux sont généralement moins efficaces que d'autres types de matériaux, ils sont utilisés dans le BCR pour les barrages, notamment au Brésil [21], et dans certains autres pays [18].

L'utilisation des additions minérales dans les mélanges de BCR peut servir à un ou plusieurs des objectifs :

- Améliorer la durabilité du BCR : minimiser la réaction alcali-granulat ;
- Comme additif pour fournir des fines supplémentaires pour optimiser la maniabilité et augmenter la compacité du mélange granulaire.
- Remplacement d'une quantité du ciment pour réduire le coût.

- **Fillers calcaires**

Les fillers calcaires sont des granulats inertes générés à partir des unités de production des granulats de type calcaire, les dimensions des fillers varie entre 0 et 1mm avec un passant au tamis 80 μm d'environ 85% avec une densité variante entre 2,1 et 2,7. L'utilisation des fillers calcaires dans le BCR minimisent la porosité et par conséquent amélioration de la compacité par le remplissage des vides intergranulaire. D'après André et Jean-Michel [22] les fillers calcaires améliorent la résistance mécanique des mélanges BCR par l'amélioration de la compacité et la réduction du rapport eau/liant. Kitouni et al. [23] dans son travail a remplacé 30% du granulat par les fillers calcaires dans un béton léger. Elle a constaté que le béton avec un niveau de remplacement de 30% de fillers calcaires peut atteindre une résistance à la compression de 34.99 MPa et 6.39 MPa de résistance à la traction. Dans un travail similaire sur la caractérisation et modélisation de la résistance à la traction des bétons à forte teneur en fillers calcaires pour les chaussées, El Euch Khay et al. [24] a prouvé la possibilité de réutiliser du sable concassé à haute teneur en charges comme constituant principal de granulats dans différents types de bétons de ciment portland, les résultats de cette étude ont montrés que les mélanges étudiés présentent des performances mécaniques intéressantes et dépassent largement les seuils de résistance. Les trois mélanges étudiés présentent des performances mécaniques intéressantes et dépassent largement les seuils de résistance requis par la norme française des bétons de chaussée (AFNOR 2006) La forte quantité de fillers calcaires provenant du sable utilisé n'affaiblit pas considérablement les résistances à la compression et à la traction fendue des mélanges testés, même si leur rapport poids/volume est relativement élevé.

Dans le BCR barrage, Berga et al. [18] ont noté que des granulats calcaires concassés présentent les meilleures propriétés pour le BCR. Si une poudre de roche est incluse, la maniabilité peut être améliorée et cette inclusion n'affectera pas la résistance du BCR. L'expérience a montré que le pourcentage inclus pouvait atteindre 17 % (des granulats fins).

Une autre étude expérimentale a montré l'amélioration des propriétés mécaniques et de la durabilité des mélanges BCR lorsque le ciment était remplacé par 15 % de calcaire broyé [25].

- **Laitier de haut fourneau**

Hadj-sadok et al. [26] notent que le laitier de haut fourneau granulé moulu (GGBFS) est un matériau assez variable en raison de la variabilité de sa composition chimique, offrant des

propriétés hydrauliques latentes lorsqu'il est mélangé avec du ciment de clinker. Ces produits proviennent du broyage fin du laitiers vitrifiés (granulé ou bouleté) qui est lui-même un co-produit de la fabrication de la fonte de haut fourneau, leur densité varie entre 2,85 et 2,95. Le laitier est utilisé dans le BCR comme remplaçant de ciment afin de minimiser la chaleur d'hydratation.

- **Cendre volante**

D'après Pandey [27] Les cendres volantes sont constitués de 80% des cendres produites dans les centrales thermiques à Charbon. Ils se composent principalement de très petites particules avec une fraction plus légère et une grande surface spécifique et une proportion plus élevée de métal (loid) à la surface. Habituellement, la gamme de couleurs FA est beige, grise à noire, qui dépend de la quantité de carbone non brûlé dans les cendres. La fraction de la cendre volante a une texture fine (0,01 à 100 µm). La cendre volante est utilisée dans le BCR dans le but de réduire le dosage du ciment afin de réduire les fissurations d'origine thermique dans le béton.

I.2.3 L'eau de gâchage

Pour convenir à la confection de bétons, l'eau ne doit pas contenir ni composés risquant d'attaquer chimiquement le ciment, les granulats ou les armatures, ni les particules en suspension dont la quantité modifiée ses qualités originelles. La norme NFP 18-303 limite cet effet le pourcentage de matières en suspension a 2 à 5 g/l et la teneur en sels dissous a 15 à 30 g/l suivant la nature du béton, précontraint ou non armé, spécification qui ne différencient pas les éléments nocifs même en très faible pourcentage de ceux qui en pourcentage éventuellement plus important ne le sont pas. Comme le BCR est un béton, l'exigence habituelle pour l'eau de gâchage dans le BCV lui est adoptée. L'exigence est qu'il soit exempt de quantités excessives d'alcalis, d'acides ou de matière organique qui pourraient inhiber le gain de force approprié.

I.2.4 Adjuvant

I.2.4.1 Généralités

L'adjuvant est un produit chimique utilisé dans les bétons au cours du malaxage dans le but d'améliorer certaines propriétés. Gauthier et al. [28], notent que la plupart des adjuvants chimiques employés pour la fabrication des bétons plastiques peuvent être employés pour le BCR. Par rapport au béton conventionnel le dosage des adjuvants utilisé dans le BCR est supérieur au dosage utilisé pour les bétons conventionnels afin d'améliorer de plus leurs propriétés. Les faibles teneurs en chlorures en solution dans certains adjuvants ne sont pas

problématiques puisque les revêtements en BCR ne contiennent pas d'armature. Par contre, des précautions doivent être prises car certains adjuvants accélèrent ou retardent la prise du béton.

I.2.4.2 Réducteur d'eau-fluidifiant

Le réducteur d'eau est très utilisé dans la construction des BCR, il consiste à réduire la quantité d'eau dans le béton pour une maniabilité donnée, il permet aussi d'améliorer la répartition de la pâte cimentaire dans le béton afin d'améliorer les propriétés mécaniques du béton. D'après Gautier et al. [28] le dosage du réducteur d'eau nécessaire pour le BCR est quatre fois supérieur au dosage nécessaire pour un béton plastique.

I.2.4.3 Retardateur et accélérateur de prise

Le but de l'utilisation du retardateur de prise dans le BCR est de ralentir l'action de la pâte cimentaire afin d'avoir un temps prolongé pour la mise en œuvre et la fabrication des BCR. De même, il est utilisé pour prolonger la mise en œuvre des joints verticaux et horizontaux.

Les accélérateurs de prise sont rarement utilisés dans les mélanges BCR qui favorisent la pâte cimentaire de dégager une chaleur d'hydratation importante, provoquant la fissuration du BCR.

I.2.4.4 Agent entraîneur d'air

A cause du faible dosage en eau dans les mélanges BCR, il est plus difficile de former des vides sphériques à l'aide d'un entraîneur d'air dans le BCR par rapport au béton conventionnel. D'après Pigeon [29] le but d'utiliser l'entraîneur d'air est de faciliter la formation des bulles d'air par la réduction de la tension de surface de l'eau et aussi pour la stabilité des bulles d'air formées durant le malaxage. Par contre, pour un dosage élevé, l'entraîneur d'air affecte le compactage du BCR. D'après Gautier et al. [11], un BCR à air entraîné contient généralement un volume d'air de 5 à 6 %.

I.3 Propriétés du BCR

I.3.1 BCR à l'état frais

I.3.1.1 Maniabilité

La maniabilité des BCR pour barrages est calculée à l'aide de l'appareil VeBe modifié selon la norme ASTM C1170-91. L'objectif principal de ce test est de déterminer le temps de vibration nécessaire à la compaction du BCR selon une procédure bien spécifique. Par ailleurs, le VeBe-test est utilisé dans des études paramétriques permettant la détermination de la teneur en eau nécessaire pour obtenir un mélange BCR adapté au compactage.

La maniabilité du BCR est influencée directement par la fluidité et le volume de la pâte. Le volume de la pâte doit remplir les vides intergranulaires lors du compactage. Une maniabilité trop élevée indique que le volume de la pâte est trop important dans le mélange BCR, cet excès de pâte influence directement les propriétés mécaniques et de durabilité du BCR. La fluidité en excès causera aussi une déformation de la surface du béton lors du passage du rouleau compacteur. Dans le cas contraire pour une maniabilité trop faible causée par un volume de pâte trop faible (teneur en eau faible), le mélange BCR marque un volume de vides important après le compactage, par conséquent une diminution dans les propriétés mécaniques et de durabilité seront remarqués. La faible maniabilité provoque aussi une ségrégation entre les grains du mélange et une réduction dans l'adhérence entre les couches et les joints. La Figure I. 1 représente une photo réelle prise lors du calcul du temps de VeBe



Figure I. 1 Détermination de la maniabilité à l'aide du test VeBe

La masse volumique du BCR à l'état frais est un paramètre essentiel pour la détermination du degré de compactage et l'uniformité des mélanges BCR. La mesure expérimentale de la masse volumique permet aussi une comparaison avec sa valeur théorique. La masse volumique du mélange BCR dépend essentiellement de la densité des granulats entrant dans leur composition. D'après Gauthier et al. [28], la méthode d'essai de la masse volumique doit représenter un degré de compactage in situ, facilement réalisable avec une consolidation adéquate du mélange. Plusieurs méthodes sont disponibles pour la détermination de la masse volumique du BCR à l'état frais [30]. Couramment, la mesure de la masse volumique humide du BCR au chantier et

au laboratoire, se fait avec une même énergie de compactage par un marteau et une hauteur de chute dans un moule normalisé selon la norme CAN/BNQ 2501-255. La Figure I. 2 illustre une photo originale prise lors de la mesure de la masse volumique.



Figure I. 2 Mesure de la masse volumique du BCR.

La mesure de la masse volumique sur chantier se fait avec le nucléo densimètre selon la norme ASTM 1040. Le degré de compactage du BCR est indiqué par le rapport entre la masse volumique humide calculée sur chantier et la masse volumique humide de référence calculée selon l'essai Proctor modifié.

I.3.1.2 Teneur en air

Pour le béton conventionnel la teneur en air est calculée selon la norme (CAN/CSA A23.2-4C) à l'aide d'un aréomètre pressiométrique, cette norme n'est pas applicable au BCR à l'état frais à cause de son affaissement. Pour le BCR la teneur en air est estimée par la comparaison entre la masse volumique humide de référence et la masse volumique humide mesuré par l'essai Proctor.

I.3.1.3 Ségrégation

La ségrégation dans un béton représente la séparation entre ses composants lors de la mise en place, le phénomène de ségrégation influence directement la résistance et l'homogénéité du BCR. À cause de leur faible dosage en eau, le BCR est très assujéti à la ségrégation. Les caractéristiques de la pâte du béton ainsi que la granularité et le diamètre maximal des granulats sont des facteurs qui influencent directement la ségrégation. Des précautions tel que la hauteur et la vitesse de chute doivent être prise en considération lors du chargement et le déchargement

dans la mise en œuvre du BCR. L'expérience a montré aussi que l'ajout des matériaux granulaire inférieur au 5mm de diamètre dans les zones ségréguées avant le passage des équipements de compactage, joue un rôle très important pour la réduction de la ségrégation. La Figure I. 3 illustre une photo du phénomène de ségrégation dans des éprouvettes confectionnées au laboratoire.



Figure I. 3 Phénomène de ségrégation sur un mélange BCR réalisé au laboratoire

I.3.2 BCR à l'état durci

I.3.2.1 Généralités

Généralement le mélange BCR à l'état durci est influencé par le type et le dosage en liant, le rapport eau/liant et la qualité des granulats, et particulièrement les propriétés des BCR à l'état durci sont influencées directement par de degré de compactage. D'après le Projet National Français BaCaRa [20], la vérification du BCR à l'état durci se fait sur des échantillons de carottage prise avant la mise en eau. Les carottes prises permettent de calculer la densité et le module d'élasticité ainsi que la résistance à la compression et à la traction.

I.3.2.2 Propriétés mécaniques

I.3.2.2.1 Résistance à la compression

La résistance à la compression du BCR est un paramètre qu'il a une grande importance dans la réalisation des barrages. D'après l'ACI [1] la résistance à la compression dans les BCR est comme un indicateur de résistance et de durabilité. La résistance à la compression dépend de

plusieurs paramètres tel que la granulométrie, la qualité et la quantité des agrégats, le dosage en eau et en ciment ainsi que la matière pouzzolanique, la proportion et la propriété des fillers. Par ailleurs, l'influence du dosage en ciment « Dc » et du rapport eau/ciment « E/C » restent parmi les plus significatives[3]. D'après Berga et al. [31] Un âge de conception variable de 180 ou 360 jours est généralement requis pour les barrages BCR. Ces âges, pour les barrages RCC, permettent une partie du développement de la résistance à long terme des bétons contenant des matières pouzzolaniques. De Larrard [32] note que la résistance à la compression du BCR dépend de nombreux paramètres importants : le taux d'eau, le taux de ciment, le type et les propriétés des fillers et enfin la qualité des granulats. Cependant, l'influence du taux de ciment "Dc" et du rapport eau/ciment "E/C" reste parmi les paramètres les plus significatifs. Rahmani et al. [33] ont montré dans leur étude expérimentale que la variation du rapport "E/C" (de 0.3 à 0.55) et du taux de ciment (de 12 à 17%) influencent significativement le temps de VEBE du BCR. Cette étude a également montré que l'augmentation du taux de ciment, en fonction de la diminution du rapport "E/C", améliore les propriétés physiques et mécaniques du BCR de la chaussée. Les mêmes auteurs, dans une autre étude expérimentale réalisée sur différents mélanges de BCR, ont démontré l'influence importante de la variation du rapport E/C sur les résistances à la flexion, à la traction et à la compression ainsi que sur le module d'élasticité du BCR [33].

I.3.2.2.2 Résistance à la flexion

D'après Tennis et al. [34], la résistance à la flexion à une grande importance dans la résistance aux fissures de la fatigue des BCR, cette résistance à la flexion est estimée généralement à partir de la résistance à la compression à l'aide d'une relation empirique, ou mesurée expérimentalement par l'essai de fendage dit essai Brisilien. D'après Ahmed et al. [35], la résistance à la traction est influencée par plusieurs paramètres, les plus importants sont les propriétés minéralogiques des agrégats, les types d'adjuvants, la teneur en humidité de l'éprouvette, les conditions de compactage et de durcissement et l'âge du béton. Chhorn et al. [15] notent que la rupture causée par la contrainte de flexion compte tenu des contraintes de traction et de compression représente l'indicateur principale de la résistance à la flexion.

I.3.2.2.3 Module élastique

A ce propos, Kalla et al. [36] notent que le module d'élasticité "E" (module de Young) représente la contrainte requise pour produire la déformation unitaire d'un béton, Selon le code

IS: 456-2000, le E du béton dépend de sa qualité et de sa résistance caractéristique à la compression. De même, Berga et al. [10] notent que le "E" dépend de l'âge d'essais et qu'il augmente avec l'âge jusqu'à atteindre une valeur maximale. Le rapport Eau/Ciment ainsi que la résistance des granulats influent directement sur la valeur de "E". Pour les mélanges BCR un module "E" faible est recherché pour diminuer le taux de fissuration. Les mélanges BCR pour barrages utilisant des fines naturelles calcaires comme fillers, aboutissent à des valeurs de E très basses.

I.3.2.2.4 Retrait

Le retrait dans un béton représente la variation de ses dimensions en absence d'un chargement extérieur. D'après Bissonnette [37] le retrait du béton est due aux phénomènes d'hydratation et de dessiccation . Il existe quatre types de retrait, le premier représente celui sans échange d'humidité, il est expliqué par la diminution du volume du squelette minéral due à la l'hydratation des composés du ciment. Le deuxième type représente le retrait avec échange d'humidité, il coïncide avec celui de séchage et au retrait plastique. Ce type est expliqué par le déplacement de l'eau vers l'extérieur à travers les pores fins et les capillaires. Le troisième type représente le gonflement dans l'eau et le dernier type représente le retrait de carbonatation qui est due à la dissolution de la chaux hydratée par le gaz carbonique. Dans le cas des BCR le retrait de séchage est plus faible par rapport au béton plastique à cause du faible teneur en ciment et du volume important du squelette granulaire compact.

I.3.2.2.5 La fatigue

D'après Gautier et Marchand [28], le phénomène de fatigue dans un béton représente l'application répétée d'une charge et du phénomène du retrait . Même les contraintes maximales engendrées par cette dernière sont inférieures à celle de la limite élastique du matériau, cette répétition peut entraîner une rupture du matériau. Agal et al. [38] ont prouvé dans leur étude que les BCR résistent mieux à la fatigue par rapport aux bétons conventionnels. L'étude du phénomène de la fatigue sur le BCR consiste à soumettre des éprouvettes à des différentes amplitude de contraintes en effort de flexion. Après le phénomène de la fatigue sera représenté dans une courbe en échelle semi-logarithmique selon l'équation :

$$f(N) = \frac{\sigma_a}{MR} \quad \text{Eq. I. 1}$$

N : le nombre de cycles

σ_a : Amplitude de contrainte

MR : module de rupture du béton

I.4 Méthodes de formulation des BCR

I.4.1 Introduction

Le BCR est un béton spécifié par rapport aux autres types de bétons par son affaissement limité, par son faible dosage de ciment ainsi que par l'utilisation des ballasts de diamètre supérieurs à 25 mm. Par ailleurs, sa mise en œuvre se fait par le biais de rouleau compacteur, contrairement aux bétons ouvrables qui sont coulés par vibration. [17]. Pour cela les méthodes de formulation des bétons conventionnels ne sont pas forcément applicables aux BCR. Des méthodes empiriques, semi-empiriques et théoriques ont été développées et testées avec succès afin de formuler le BCR et d'atteindre ses propriétés recherchées [8].

I.4.2 Domaine d'utilisation

I.4.2.1 Pavage

Récemment l'application des BCR dans la construction des chaussées a été considérablement développée. Actuellement le BCR est considéré comme le plus commode et plus économique dans leur construction aux chaussées réalisées avec du béton conventionnel [33]. D'après Hazaree et al. [39] la construction des pavages par les mélanges BCR peut entraîner des économies variables de 15 à 40 % par rapport au béton conventionnels.

I.4.2.2 Barrage

D'après Broucek et al. [40] la première proposition d'utilisation des BCR pour la construction des barrages date de 1941. Au cours des années 1970 des essais sur des massifs à grandes échelles ont été réalisés aux États-Unis [41], au Royaume-Uni [42] et par la suite au Japon [40]. La première application de la technique BCR pour la réalisation d'un corps de barrage a été conduite aux États-Unis en 1982 [43]. Au cours des années 90 l'utilisation des BCR au corps des barrages a été largement diffusée et utilisée notamment en Brésil, Japon, États-Unis et en Espagne.

I.4.3 Méthodes de formulation

Les méthodes de formulations des mélanges BCR sont classées généralement en trois grandes méthodes : empirique, semi-empirique et théorique.

I.4.3.1 Méthodes empiriques

D'après le comité ACI [16], les méthodes empiriques sont considérées dans la première catégorie pour réaliser les mélanges BCR. Cette conception est basée généralement sur un grand nombre de gâchés d'essais au laboratoire afin d'atteindre les caractéristiques souhaitées. Calis et Yıldız [44] notent que la réalisation d'autres combinaisons d'essais sur le site est parfois nécessaire pour l'ajustement de la maniabilité [1]. Ce type de formulation reste efficace et simple à utiliser mais nécessite du temps et de l'énergie pour corriger et adopter la formulation recherchée. Selon le comité ACI [16], il existe diverses méthodes empiriques pour formuler un BCR, les plus couramment utilisées sont la méthode de formulation respectant des limites de maniabilité et la méthode de formulation selon des principes de géotechnique.

I.4.3.1.1 Méthode de formulation avec des limites de maniabilité

D'après le rapport de l'ACI 211.3R-02 [45], cette méthode utilise l'essai Vebe modifié selon la norme ASTM C1170, comme base pour déterminer l'ouvrabilité optimale et les proportions des différents agrégats du mélange BCR. Le temps de vibration pour la consolidation complète est mesuré et comparé aux essais de compactage sur le terrain effectué avec des rouleaux vibrants. Le temps souhaité est déterminé sur la base des résultats des essais de densité. Le temps de vibration est influencé par un certain nombre de paramètres du mélange, y compris la teneur en eau, la granulométrie des agrégats combinés, la taille maximale des agrégats, la teneur en agrégats fins et la teneur en matériaux plus fins, de diamètre inférieur à 75 μm . Les mélanges granulaires ayant un diamètre maximale comprise entre 19 et 38 mm ont généralement besoin de 15 à 30 secondes pour se consolider complètement par contre les mélanges ayant un diamètre maximal de 19 mm ou moins ont besoin d'environ 35 à 50 secondes

I.4.3.1.1.1 Teneur en eau

D'après l'ACI 325.10R-95 [46], les mélanges dont les volumes de pâte dépassent les volumes de vide des agrégats se consolideront complètement à environ 98 % de leur densité théorique telle que définie par la norme ASTM C 138. Les variations de la teneur en eau du mélange auront une influence directe sur l'effort de compactage nécessaire pour avoir une consolidation complète. La teneur en eau optimale d'un mélange donné est celle dont la variabilité a le moins d'effet sur l'effort de compactage pour une consolidation complète. Si la teneur en eau d'un mélange est trop faible, les vides entre les agrégats ne seront plus remplis de pâte et la force du mélange diminuera même si le rapport Eau/Ciment a diminué. La Figure I. 4 montre un exemple

de variation de la résistance en fonction de la teneur en eau pour une teneur fixe en matériaux cimentaires.

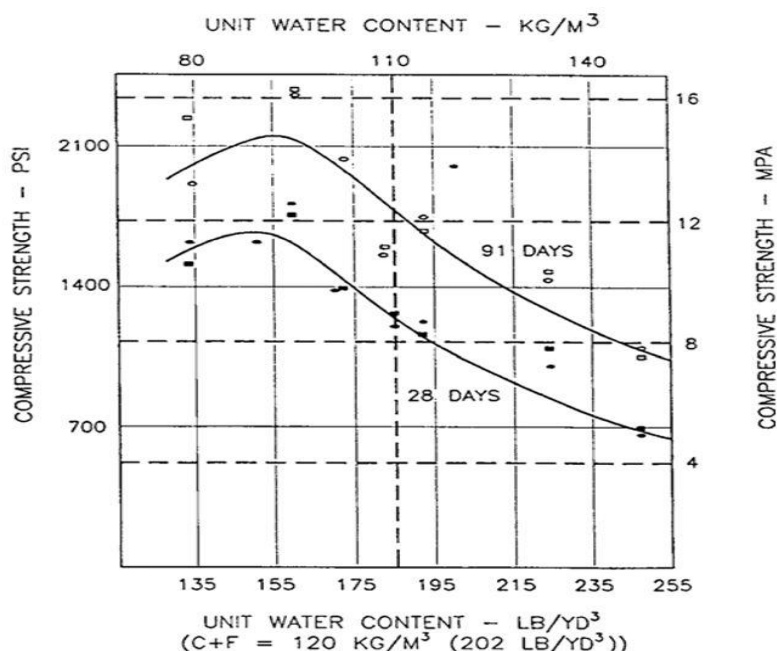


Figure I. 4 Relation entre la teneur unitaire en eau et la résistance à la compression du béton.

I.4.3.1.1.2 Teneur en matériaux cimentaires

D'après le rapport de l'ACI 211.3R-02 [45] la teneur en matériaux cimentaires utilisée dans les mélanges BCR dépend de la résistance spécifiée, de l'exigence de liaison entre les couches et de considérations relative aux propriétés thermiques. Pour une teneur donnée en matériaux cimentaires, la résistance à un âge donné sera maximisée lorsque le volume de pâte est juste suffisant pour remplir les vides des agrégats. La résistance sera réduite si le volume de la pâte n'est pas suffisant pour remplir les vides d'air emprisonnés ou si la teneur en eau est augmentée au point de créer un excès de pâte avec un rapport E/C plus élevé. Par conséquent, lorsque la teneur en pâte augmente, la teneur en eau peut être réduite et la résistance optimisée sans perte de maniabilité. Pour la plupart des ciments (type I ou II selon ASTM C 150), la Figure I. 5 est utilisée comme guide pour proportionner les BCR de résistance égale pour différentes proportions de ciment portland et de pouzzolanes ASTM C 618 de classe F. On peut s'attendre à des résultats similaires avec d'autres pouzzolanes. L'utilisation d'essais de résistance à la compression du mortier s'est également avérée être un moyen approprié pour déterminer le rapport E/C requis pour les considérations de résistance. Une fois que le mortier est proportionné pour répondre aux exigences de résistance, différents pourcentages de mortier et

de gros agrégats peuvent être optimisés pour obtenir une maniabilité donnée, mesurée par le temps VeBe. Ces opérations sont basées sur une quantité de mortier requise par unité de volume de BCR.




Figure I. 5 Courbes de dosage pour un béton à résistance égale

I.4.3.1.1.3 Teneur en agrégats fins

La teneur en vides des agrégats fins pour un BCR varie normalement de 34 à 42 % [45]. Le volume minimal de pâte peut être déterminé par des courbes de densité maximale, de la même manière que la teneur optimale en eau est déterminée dans les sols. L'agrégat fin est ajouté par des pourcentages égaux à la pâte proportionnée à la masse volumique déterminée pour le mélange, et les mesures de densité des échantillons sont effectuées selon la norme ASTM D 1557. Les valeurs de densité sont représentées sur un graphique en fonction des volumes de pâte calculés et le volume produisant la densité maximale des échantillons de mortier peut être déterminé. Le volume de pâte, par rapport au volume total de mortier, doit être augmenté de 5 à 10% pour les mélanges de béton de masse, et de 20 à 25% pour les mélanges conçus pour être

utilisés lorsqu'un mortier de liaison n'est pas utilisé entre les levées horizontales de BCR. La Figure I. 6 illustre les démarches de détermination de la masse volumique optimale.




Figure I. 6 Volume optimal d'un mortier pour BCR [2]

I.4.3.1.1.4 Teneur en gros granulats

Le volume minimal de granulats permettant d'obtenir une consistance sans affaissement est déterminé en dosant la fraction de mortier pour obtenir la résistance approximative requise, puis en ajustant les proportions de gros granulats et de mortier pour obtenir un affaissement nul [45]. Une fois que le rapport gros granulat/mortier qui donne un affaissement nul est déterminé, le gros granulat peut être augmenté jusqu'à ce que le rapport soit atteint, ce qui donne le temps Vebe modifié souhaité. Le volume absolu de gros granulats par unité de volume de BCR se situe généralement dans les limites du Tableau I. 3

Tableau I. 3 Volumes absolus recommandés de gros granulats par unité de volume de BCR

NMSA*, mm (in.)	Absolute volume, % of until RCC volume
150 (6)	63 to 64
115 (4-1/2)	61 to 63
75 (3)	57 to 61
37.5 (1-1/2)	52 to 56
19 (3/4)	46 to 52
9.5 (3/8)	42 to 48

*NMSA = nominal maximum size aggregate.

I.4.3.1.1.5 Étapes de formulation

La méthode de formulation du BCR se fait selon les étapes suivantes [45] :

➤ **Étape 1**

Sélectionnez le rapport volumétrique pouzzolane-ciment (p/c) et w/(c+p) de la **Figure I. 5** pour la production des lots de mortier et de béton d'essai.

➤ **Étape 2**

Déterminer la teneur minimale en pâte P_T en pourcentage du volume total du mortier en utilisant les procédures précédemment décrites. Comme alternative, on peut choisir le rapport entre le volume de pâte sans air et le volume de mortier sans air P_v , dans la plage de 0,38 à 0,46. Il convient d'accorder une attention particulière à la sélection de cette valeur si elle n'est pas basée sur des résultats d'essais spécifiques.

➤ **Étape 3**

Déterminer le volume de gros granulat, V_{CA} , par les méthodes d'essai décrites précédemment jusqu'à l'obtention du temps $VeBe$ modifié souhaité ou par sélection dans le Tableau I. 3

➤ **Étape 4**

Supposer que la teneur en air piégé est de 1,0 à 2,0 % du volume total du béton et de calculer le volume d'air dans le mélange à partir de la formule suivante :

$$V_A = (\text{teneur en air}/100) \times C_V$$

➤ **Étape 5**

Calculez le volume de pâte sans air, V_P , à partir de ;

$$V_P = (P_T/100 \times V_{MT}) - V_A$$

Où

$$V_{MT} = \text{Volume total de mortier}$$

$$= C_V - V_{CA}$$

Ou si une valeur de P_v est sélectionnée à l'étape 2

$$V_P = V_m \times P_v$$

Où

V_m = volume de mortier sans air

$$= C_V - V_{CA} - V_A$$

➤ **Étape 6**

Déterminer le volume d'agrégat fin, V_{FA} , à partir des formules suivantes :

$$V_{FA} = C_V - V_{CA} - V_P - V_A$$

Où

$$V_{FA} = V_m \times (1 - P_v)$$

➤ **Étape 7**

Déterminer le volume d'eau d'essai, V_w , à partir de la formule suivante :

$$V_w = V_P \times w/(c+p) / [1 + w/(c+p)]$$

Où

$w/(c+p)$ = rapport eau-matériaux cimentaires, en volume .

➤ **Étape 8**

Déterminer le volume de ciment, V_C , à partir de de la formule suivante :

$$V_C = V_w / \{w/(c+p) \times [1 + (p/c)]\}$$

➤ **Étape 9**

Déterminer le volume de pouzzolane, V_F , à partir de la formule suivante :

$$V_F = V_C \times (p/c)$$

➤ **Étape 10**

Calculer la masse de chaque matériau en multipliant son volume absolu par sa masse volumique apparente respective.

➤ **Étape 11**

Effectuer des tests de cohérence sur les lots d'essai comme indiqué précédemment pour obtenir le temps de VeBe modifié souhaité ou pour déterminer la durée minimale de vibration nécessaire pour obtenir la densité maximale de compactage.

➤ **Étape 12**

Après la sélection des volumes d'agrégats finaux, préparer au moins deux lots supplémentaires, l'un ayant une masse volumique apparente supérieure et l'autre une masse volumique apparente inférieure. Tracer la résistance en fonction de la masse volumique pour déterminer les proportions du mélange final.

I.4.3.1.2 Méthode de formulation selon des principes de la géotechnique

Cette méthode a été développée par le comité ACI [47], dont le principe général se base sur le principe utilisé dans le compactage du sol. Elle consiste à déduire la teneur en eau des mélanges BCR pour une masse volumique sèche.

Dans un premier temps, le rapport d'agrégats fin aux agrégats grossier est déterminé à l'aide du fuseau granulométrique qui est représenté par la Figure I. 7. Les gâchées de bétons sont réalisées pour différentes teneur en liant. La teneur en eau est variée selon la méthode ASTM C1557-Method D, dans le but d'atteindre une teneur optimale pour le mélange BCR sec. Chaque mélange réalisé est compacté dans un moule cylindrique normalisé sous une énergie de compactage spécifique. Par la suite, la masse volumique humide est calculée pour chaque masse volumique sec. La valeur de de la teneur en eau pour un mélange à masse volumique sèche opale est déterminée par la valeur maximale de la courbe de la Figure I. 8. Des résistances à la compression sont réalisées ensuite pour les différents mélanges réalisés. Gauthier et al. [28] notent que le mélange requis pour l'utilisation est celui qui possède des propriétés mécaniques acceptables avec une teneur en liant optimale.




Figure I. 7 Fuseau granulométrique d'un BCR [28]

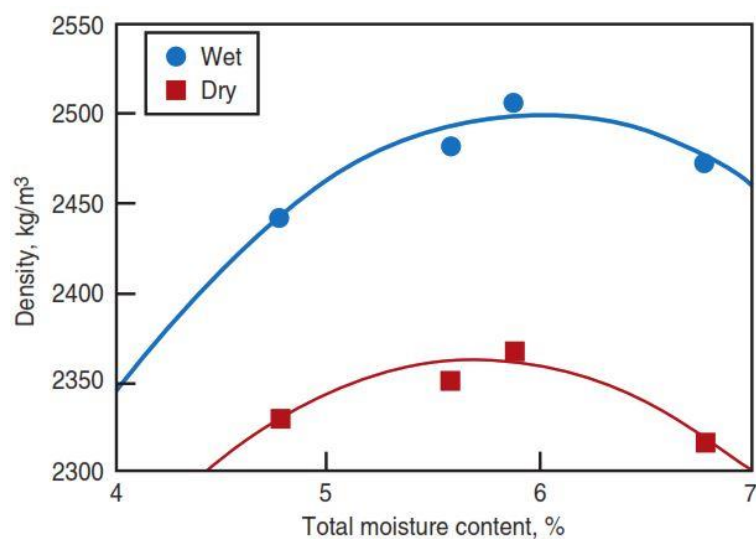


Figure I. 8 Relation entre la teneur en eau et la densité d'un mélange BCR [28].

a) Teneur en matériaux cimentaires

La teneur en matériaux cimentaires est déterminée par la résistance à la compression ou à la flexion à la teneur en eau optimale pour différents mélanges. La teneur en matériaux cimentaires est exprimée en pourcentage de la masse sèche des agrégats. La teneur en matériaux cimentaires pour les chaussées BCR varie généralement de 10 à 17 %, en fonction des exigences de résistance et de durabilité.

b) Teneur en granulats fins et grossier

Les granulats fins et grossiers doivent être mélangés pour créer un granulats combiné de grade dense. Le volume de granulats fins et grossiers par unité de volume de béton est déterminé après avoir déterminé la teneur en eau optimale du mélange granulats-matériau cimentaire.

c) Teneur en eau

Pour un effort de compactage donné, la teneur en eau optimale du mélange dépend des propriétés des granulats utilisés et de la teneur en matériaux cimentaires. Une perte de résistance se produira avec une teneur en eau inférieure à l'optimum. Cela est dû à une pâte insuffisante et à la présence de vides entre les particules de granulats. Une perte de résistance se produit également si la teneur en humidité est nettement supérieure à l'optimum en raison d'une augmentation de la teneur en eau. La teneur en humidité (en masse) est exprimée en pourcentage de la masse sèche du mélange agrégats-matériau cimentaire et doit être déterminée conformément à la norme ASTM C 566. Après l'achèvement des essais de compactage effectués

à des teneurs en humidité croissantes, les points de données de densité d'humidité sont tracés, et une courbe lisse est tracée à travers eux. Le pic de la courbe parabolique établit la teneur en humidité optimale (Figure I. 9).

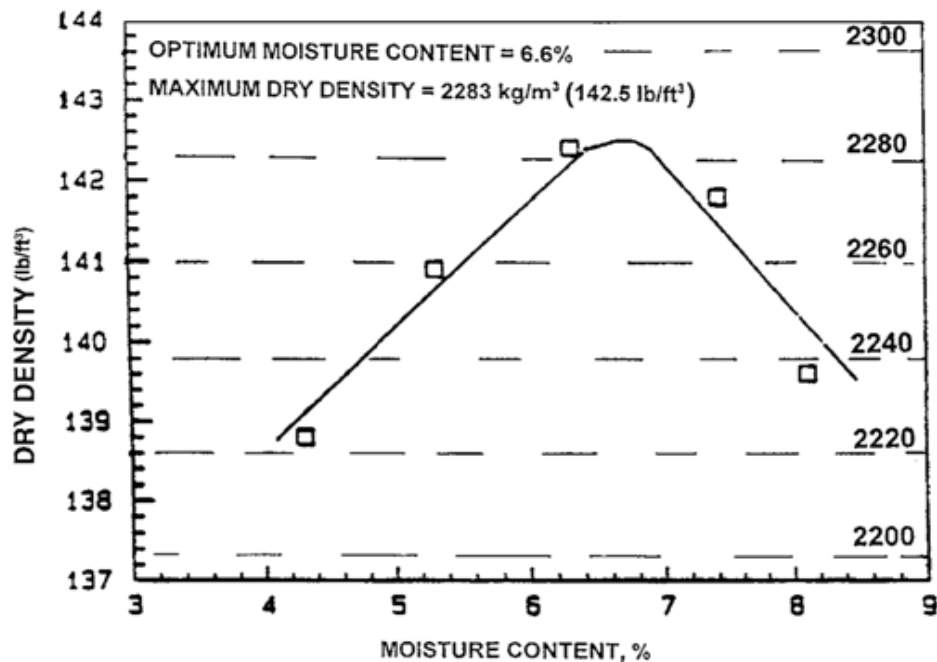


Figure I. 9 Relation type humidité-densité sèche.

d) Étapes de dosage

Les méthodes de formulations ont été pris à partir du rapport ACI 211.3R-02 [45]

➤ **Étape 1**

Sélectionner une teneur en matériaux cimentaires en fonction de la résistance à la compression ou à la flexion. Pour un BCR ayant des résistances à la flexion spécifiées, déterminées conformément à la norme ASTM C 78, de 4 à 5 MPa ou 600 à 700 psi, la quantité de matériaux cimentaires utilisée doit se situer entre 12 et 16 % en masse d'agrégats secs. La valeur choisie dépendra en partie du type et de la quantité de pouzzolane utilisée.

➤ **Étape 2**

En utilisant la teneur combinée des agrégats et des matériaux cimentaires sélectionnés, déterminer la teneur optimale en humidité du BCR conformément à la norme ASTM D 1557. Un minimum de quatre échantillons de densité d'humidité doit être moulé, et chaque échantillon doit être préparé à partir d'un lot de BCR à des taux séparés pour éviter une hydratation excessive du ciment. Chaque lot successif doit contenir une teneur en humidité plus élevée que

les précédents. Pour ce faire, il faut ajouter suffisamment d'eau au lot pour augmenter la teneur en humidité du BCR, en pourcentage de la masse sèche du BCR de 0,75 à 1,0 %.

➤ **Étape 3**

Déterminer la teneur en eau optimale en traçant la masse sèche de chaque échantillon en fonction de sa teneur en eau respective et en traçant une courbe lisse à travers ces points (Fig. 3.3). La teneur en humidité et la densité sèche correspondant au pic de cette courbe sont l'humidité optimale.

➤ **Étape 4**

Supposons une teneur en air piégé de 2,0 %. (La valeur réelle peut être calculée à partir des résultats des tests de compactage et de la courbe zéro des vides d'air).

➤ **Étape 5**

Utilisant la teneur en humidité optimale, la teneur en matériaux cimentaires sélectionnés et la valeur de la teneur en air, calculer les volumes et masses absolus des matériaux pour l'unité de volume de béton requise.

➤ **Étape 6**

Suivre les étapes 2 à 6 en utilisant une teneur en matériaux cimentaires plus élevée et plus faible. Après avoir produit des lots d'essai à la teneur en humidité optimale pour chaque teneur en matériaux cimentaires, tracez la résistance en fonction de la teneur en matériaux cimentaires pour déterminer la valeur nécessaire pour les proportions finales du mélange. Suivre de nouveau les étapes 2 à 6 avec la teneur en matériaux cimentaires sélectionnée pour déterminer la teneur optimale en humidité et déterminé les volumes absolus et la masse des matériaux.

Il est toutefois à noter que la méthode de formulation à des limites de maniabilité reste plus précise et efficace par rapport à la méthode de formulation selon des principes de la géotechnique [2]. Cette méthode permet de réaliser des mélanges de BCR bien optimisés proches de la réalité par contre la méthode de géotechnique donne dans la majorité des cas des valeurs loin de l'optimale [2]. Dans les deux méthodes citées, l'utilisateur reste obligé de réaliser plusieurs mélanges d'essais de BCR afin de déterminer le mélange optimum avec les caractéristiques désirées.

I.4.3.2 Méthode semi-empirique

La méthode semi-empirique est fondée conjointement sur des formules empiriques et des données expérimentales. L'approche du volume de pâte optimal est la plus utilisée. Dans cette méthode, les différents constituants du mélange BCR sont déterminés en s'appuyant sur la mesure de volume de la pâte en fonction du volume des vides. Cette théorie nécessite la formulation de certains gâchées d'essais [28]. D'après Gagné [48] l'objectif principal de cette méthode est de réaliser un mélange BCR avec un volume de pâte optimal pour remplir les vides intergranulaires après le compactage afin d'atteindre une densité maximale. Cette méthode s'appuie dans leur principe général sur l'approche volumétrique. Pour un volume de pâte en excès le BCR doit avoir un problème représenté dans le dégagement de chaleur lors de l'hydratation du ciment et qu'il influe directement sur les propriétés physiques du mélange ainsi que sur le cout de la construction. Pour un volume de pâte infusant, le mélange aura un problème de ségrégation qu'il influe sur l'augmentation de la perméabilité et les propriétés mécaniques du mélange. Cette méthode permet de réaliser des mélanges BCR sans air entraîné. Gagné [48] note que la réalisation d'un BCR avec air entraîné dans cette méthode est complexe à cause de l'influence du réseau de d'air sur les propriétés mécaniques du BCR et aussi sur la maniabilité. D'après Gagné [48] le principe général de cette méthode est décrit selon trois étapes essentielles:

➤ *Etape 1 : Définir un squelette granulaire optimal et déduire le volume des vides*

Cette étape comporte à définir les différentes proportions du mélange granulaire à sec de tel façon dans le but d'atteindre un mélange avec un minimum de vides.

Gagné [48] note que la formule de Fuller-Thompson est souhaitable pour l'utilisation afin de produire un squelette granulaire dense.

$$p = \left(\frac{d}{D}\right)^{0,45} \times 100 \quad \text{Eq. I. 2}$$

d : Taille des tamis (mm);

D: Diamètre maximale des granulats (mm);

p : Pourcentage des passants (%) des particules dans un tamis de grosseur d.

La Figure I. 10 représente les différentes courbes granulométriques spécifiques de Fuller-Thompson pour des mélanges granulaires ayant des différents diamètres maximaux de

granulats. Ces courbes indiquent la nécessité d'introduire un pourcentage de 10 à 15 % de fines particules passant dans le tamis de 160 μm , le pourcentage implique les fines de nature granulaires et de natures cimentaire [48]

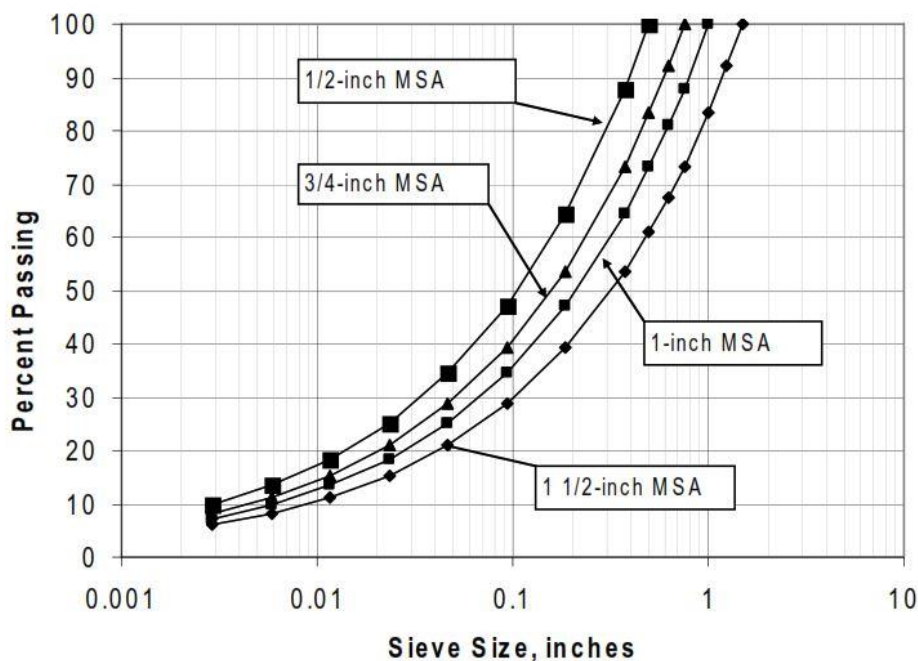


Figure I. 10 Courbes Fuller-Thompson modifiées pour différentes tailles d'agrégats [29].

Le degré de compactage des mélanges granulaires est influencé directement par la méthode de compactage, par la forme des granulats et aussi par la rugosité des fines ayant un diamètre maximale inférieur à 5 mm. Cette variation selon Gagné [48] peut atteindre ou dépasser les 20%. Après la détermination de la courbe granulométrique optimale, le volume des vides (V_v) est calculé à l'aide de l'appareil VeBe. Ce procédé comporte sur le compactage d'un mélange de grains à l'aide d'une table vibrante dans un moule cylindrique normalisé et sous une charge de (10Kpa). Après le compactage le volume des vides est déterminé par rapport au volume total du moule cylindrique. D'après Gauthier et al. [28] un BCR de haute performance doit avoir un volume des vides après une compaction inférieure à 180 l/m^3 .

➤ Etape 2 : Détermination du volume optimal de la pâte pour une maniabilité souhaitée

A ce propos, Gauthier et al. [28] notent que l'objectif de cette étape est de déduire le volume de pâte optimum pour une maniabilité désirée. L'influence du rapport de volume de la pâte et le volume des vides du mélange après compactage sur la maniabilité de mélange BCR sans air entrainé a été prouvée par divers travaux expérimentaux. Le volume de la pâte représente le volume d'eau en addition avec le volume de ciment et des ajouts minéraux.

$$V_p = V_{\text{eau}} + V_{\text{ciment}} + V_{\text{ajout minéraux}}$$

Eq. I. 3

La Figure I. 11 illustre la relation entre le rapport V_p/V_{vc} et la maniabilité. Les valeurs du volume de pâte et du vide sont exprimées en (l/m^3) dans un volume de mélange de BCR de $1 m^3$. A partir d'une maniabilité désirée et un volume des vides déjà calculés, le volume de la pâte est obtenu à partir de la Figure I. 11. La maniabilité du mélange pour être ajustée par une variation légère de volume de la pâte. Cette relation demeure approximative dans la mesure où la relation exacte dérive de la fonction de la méthode utilisée pour déterminer V_{vc} et des propriétés rhéologiques de la pâte [4.2]. À partir de la Figure I. 11, on détermine le volume de pâte (l/m^3) requis pour une maniabilité désirée. Généralement, le rapport V_p/V_{vc} compris entre 1,0 et 1,05 permet d'atteindre une maniabilité variable de 40 à 90 secondes et mesurée à l'aide de l'appareil VeBe. Une ou deux gâchées de vérification sont par ailleurs requises pour déterminer le dosage exact du volume de pâte nécessaire pour obtenir la maniabilité désirée. D'après Gagné [2] le temps VeBe pour un BCR barrage est compris entre 10 et 20 secondes par contre pour un BCR pour pavages le temps de VeBe varie de 30 à 90 secondes.

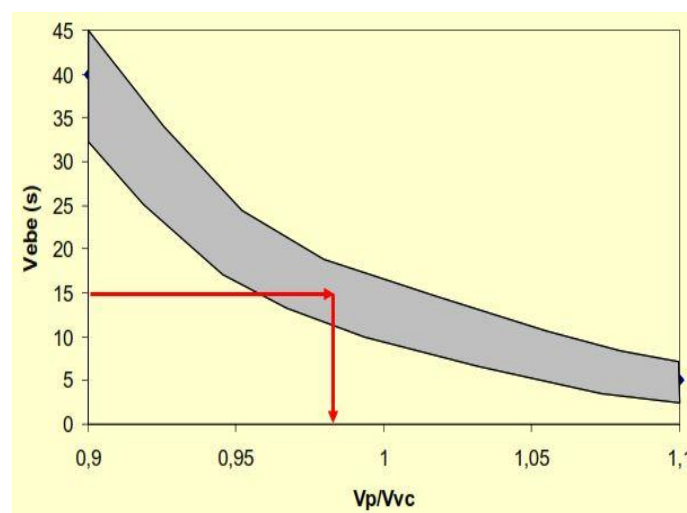


Figure I. 11 Relation expérimentale entre l'ouvrabilité et le rapport du volume et la capacité des vides pour un BCR barrage sans air entrainé [30]

➤ **Etape 3 : Définir le rapport eau/liant pour une résistance à la compression souhaitée**

L'étape finale de cette méthode consiste à définir le type de liant et le rapport eau/liant (E/L) afin d'atteindre une résistance du BCR définie. Un nombre limité de gâchées d'essais et suffisant pour définir un rapport E/L pour une résistance du BCR voulue. La conception des revêtements doit être conduite à partir de la résistance à la flexion du mélange BCR. Pour cela, la résistance à la flexion doit être estimée à partir de la résistance à la compression ou à partir des courbes expérimentales qui relient la résistance à la flexion pour différents rapports E/L.

I.4.3.3 Méthodes théoriques

La plupart des méthodes de dosage de formulation des BCR sont essentiellement des procédures empiriques qui nécessitent souvent la production de nombreux gâchées d'essai pour obtenir la proportion de mélange optimale. Afin de résoudre ce problème, des méthodes théoriques ont été introduites. Elles reposent sur une meilleure compréhension des paramètres qui affectent les propriétés à l'état frais et durci du BCR. Pour ces méthodes, le nombre de gâchées d'essai nécessaires pour obtenir les proportions de mélange optimales est généralement limité. Comme il a été indiqué, principalement, la formulation des BCR s'appuie sur l'optimisation de son mélange granulaire et sur la maîtrise de sa compacité. Ainsi, les principaux modèles théoriques de modélisation des mélanges granulaires, vont être présentés dans ce qui suit [6].

I.4.3.3.1 Le modèle linéaire de compacité (MLC)

➤ **Mélanges binaires sans interactions**

D'après Stovall et al. [49] dans un mélange granulaire ayant deux classes de grains 1 et 2, on dit que les deux classes sont sans interaction l'orsque $d_1 \gg d_2$.

Pour calculer la compacité virtuelle γ d'un mélange de grain, il est nécessaire de mesurer la compacité individuelle β_1 et β_2 de chaque classe de grain.

Si les volumes partiels de chaque classe dans l'unité du volume de mélange sont désignés par \emptyset_1 et \emptyset_2 et y_1 et y_2 représentent les proportions volumiques de chaque classe granulaire, alors :

$$y_1 + y_2 = 1 \quad \text{Eq. I. 4}$$

$$y_1 = \frac{\emptyset_1}{\emptyset_1 + \emptyset_2} \quad \text{et} \quad y_2 = \frac{\emptyset_2}{\emptyset_1 + \emptyset_2} \quad \text{Eq. I. 5}$$

Ainsi, la compacité γ est :

$$\gamma = \emptyset_1 + \emptyset_2 \quad \text{Eq. I. 6}$$

- Lorsque les gros grains sont dominants (Figure I. 12) on a :

$$\emptyset_1 = \beta_1$$

$$\gamma = \emptyset_1 + \emptyset_2 = \beta_1 + \emptyset_2$$

$$\gamma = \beta_1 + \emptyset_2 = \beta_1 + \emptyset_2$$

$$\gamma = \beta_1 + y_2 (\emptyset_1 + \emptyset_2)$$

$$\gamma = \gamma_1 = \frac{\beta_1}{1 + y_2} \quad \text{Eq. I. 7}$$




Figure I. 12 Mélange binaire sans interaction avec gros grains dominants [9]

- Lorsque les grains de petit diamètre sont dominants (Figure I. 13) on a :

$$\emptyset_2 = \beta_2 (1 - \emptyset_1) \quad \text{Eq. I. 8}$$

$$\gamma = \gamma_2 = \frac{\beta_2}{1 - (1 - \beta_2) y_1} \quad \text{Eq. I. 9}$$




Figure I. 13 Mélange binaire sans interaction avec petit grains dominants [9].

➤ **Mélange de n classes binaires sans interactions**

Pour un mélange granulaire de n classe de grain ($n > 2$) tel que $d_1 \gg d_2 \dots \gg d_n$

$$V_i = \frac{\beta_i}{1 - y_i \dots - y_{i-1}(1 - \beta_i)(y_{i+1} \dots + y_n)} \quad \text{Eq. I. 10}$$

➤ **Mélange de n classes avec interaction**

D'après de Larrard [3] ce procédé consiste de prendre un mélange ternaire avec:

$$d_1 \geq d_2 \geq d_3$$

Ce procédé suppose que la classe 2 soit dominante, donc les grains sont soumis à un effet de desserrement exercé par les grains 3, et à un effet de paroi exercé par les grains 1 (Figure I. 14)




Figure I. 14 Perturbation exercée par les gros et les petits grains sur la classe intermédiaire [9].

La compacité du mélange dans ce cas est :

$$C_{MLC}^i = \frac{\alpha_i}{1 - (1 - \alpha_i) \sum_{j=1}^{i-1} g(i,j)y_j - \sum_{j=i+1}^n f(i,j)y_j} \quad \text{Eq. I. 11}$$

Avec :

- C_{MLC}^i : compacité virtuelle du mélange pour la classe " i " dominante
- n : nombre de classes granulaires.
- α_i : Compacité expérimentale de la classe " i " prise isolément.
- y_j : proportions volumiques (par rapport au volume solide total).
- $f(i,j)$: fonction d'interaction " effet d'interférence "
- $g(i,j)y_j$: fonction d'interaction " effet de paroi ".

- **L'effet de desserrement**

L'effet de desserrement apparaisse lorsqu'un grain n'est pas suffisant fin pour pénétrer dans la porosité des gros grains. D'après de Larrard [3] lorsque les tétraèdres élémentaires des gros grains, dilatés par la présence d'un petit grain, sont suffisamment éloignés les uns des autres, la perturbation est linéaire par rapport au volume de grains étrangers.

- **L'effet de la paroi du récipient**

A côté de la paroi du récipient, la répartition des grains n'est pas libre. La compacité au contact et au prêt de la paroi est plus faible par rapport au centre du récipient (Figure I. 15). Cet effet disparaître pour un rapport " diamètre du récipient d_R / diamètre des particules $d_{max} > 10$ [3].




Figure I. 15 Effet de paroi exercé par un gros grain dans un empilement de grains fins [9].

Malgré l'efficacité de ce modèle, il présente deux inconvénients :

- Le modèle ne traite pas le cas d'un mélange granulaire ayant des diamètres de grain similaire,
- Dans le cas de forte compacité, le modèle surestime sa valeur.

Cherit [50] a réalisé une étude comparative entre les résultats expérimentaux des compacités de mélanges granulaires binaires et les compacités calculées avec le modèle linéaire de compacité. Les résultats de l'étude montrent une sous-estimation des valeurs de la compacité au voisinage de l'optimum.

I.4.3.3.2 Le modèle d'empilement virtuel

Le modèle d'empilement compressible est une version corrigée du modèle de compacité linéaire. Ce modèle a été développée au laboratoire de LCPC et décrit par de Larrard [3]. Ce modèle Prend en considération le cas d'un mélange ayant les mêmes tailles de grain avec de compacités propres différentes (Figure I. 16).




Figure I. 16 Deux classes granulaires avec le même diamètre [33].

Dans ce modèle les notions β et γ représente les notions α et C_{MLc} du modèle linéaire.

γ représente la compacité virtuel du mélange et β c'est la compacité virtuelle de chaque classe prise isolément. Afin d'améliorer le modèle linéaire, de Larrard a considéré deux classes de grain de mêmes diamètre $d_1 = d_2$ ayant des compacités propres différentes $\beta_1 \neq \beta_2$ (figure 2.14).

$$\frac{\emptyset_1}{\beta_1} + \frac{\emptyset_2}{\beta_2} = 1 \quad \text{Eq. I. 12}$$

$$\gamma = \gamma_1 = \frac{\beta_1}{1 - y_2(1 - \beta_1/\beta_2)} \quad \text{Eq. I. 13}$$

Si en remplaçant les compacités dans les différentes cas du modèle linéaire, on trouve pour le cas de mélange sans interaction ($d_1 \gg d_2$) :

- Cas de gros grains dominants :

$$\gamma_1 = \frac{\beta_1}{1 - y_2} \quad \text{Eq. I. 14}$$

- Pour petit grains dominants

$$\gamma_2 = \frac{\beta_1}{1 - (1 - \alpha_2)y_1} \quad \text{Eq. I. 15}$$

de Larrard a intégré les trois cas précédents dans une seule équation:

$$\gamma_1 = \frac{\beta_1}{1 - (1 - a_{12}\beta_1/\beta_2)y_1} \quad \text{Eq. I. 16}$$

et

$$\gamma_2 = \frac{\beta_1}{1 - [1 - \beta_2 + b_{21}\beta_2(1 - 1/\beta_1)]y_1} \quad \text{Eq. I. 17}$$

Le coefficient a_{12} représente le desserrement exercé par les grains 2 sur l'empilement des grains 1.

1. a_{12} est égale à 0 dans le cas ($d_1 \gg d_2$) et à 1 pour ($d_1 = d_2$).

Le coefficient b_{12} représente l'effet des parois exercé par l'empilement des grains au voisinage d'un grain 1. Ce coefficient admet les mêmes conditions aux limites que le coefficient a_{12} . A la fin, pour un mélange granulaire de n classe, la compacité virtuelle d'un empilement de grain ce résume dans l'équation I.18 :

$$\gamma_i = \frac{\beta_i}{1 - \sum_{j=1}^{i-1} y_j \left(1 - a_{ij} \frac{\beta_i}{\beta_j}\right) - \sum_{j=i+1}^N y_j \left(1 - \beta_j + b_{ij} \beta_i \left(1 - \frac{1}{\beta_j}\right)\right)} \quad \text{Eq. I. 18}$$

Avec :

γ_i : compacité virtuelle du mélange pour la classe "i" dominante

β_i : compacité propre virtuel de la classe "i".

a_{ij} : effet de paroi

b_{ij} : effet de desserrement

n : nombre de classe granulaire

y_j : proportions volumiques par rapport au volume solide total

Ce modèle a été aussi développée par la détermination des coefficients a_{ij} et b_{ij}

I.4.3.3 Le modèle de suspension solide (MSS)

Actuellement, le domaine de la conception de mélanges de béton a connu des développements rapides. L'une des avancées majeures dans ce domaine est l'introduction de méthodes théoriques permettant de concevoir du béton avec des densités de tassement optimales.

L'une des méthodes les plus prometteuses est celle développée par le laboratoire des Pont et des Chaussées (LCPC). Ce modèle est une version améliorée d'une méthode précédente, qui a été développée à l'origine pour concevoir des mélanges de béton à haute performance. Le modèle de suspension solide a été adapté et testé avec succès, pour concevoir des mélanges BCR pour les applications des barrages et des chaussées. Il a également été utilisé pour doser des mélanges à haute performance pour la construction de projets BCR à grandes échelles dans l'est du Canada.

Fondamentalement, le modèle peut être utilisé pour prédire la compacité d'un arrangement de grains de différents diamètres d_i ($d_1 > d_2 > \dots > d_n$) sur la base :

1. de la densité de tassement intrinsèque (α_i) de chaque classe de grains (c'est-à-dire la densité de tassement d'un agencement de grains de diamètre d_i similaire) ;
2. de la proportion massique y_i de chaque classe de grains (exprimée en rapport du volume solide total).

Le modèle en suspension solide repose sur l'hypothèse que la viscosité relative de référence (η_r^*) d'un arrangement de grains, consolidé par tout type de technique, a une valeur finie. Pour une disposition unimodale de grains de diamètre d_i , la viscosité relative de référence peut être calculée à l'aide de l'équation suivante :

$$\eta_r^* = \exp\left(\frac{2.5}{\frac{1}{\alpha_i} - \frac{1}{\beta_i}}\right) \quad \text{Eq. I. 19}$$

où β_i représente la densité de tassement virtuel intrinsèque de la classe de grains (i).

En pratique, les valeurs réelles de α_i pour chaque classe de grains peuvent être facilement déterminées expérimentalement.

Une fois que les valeurs de β_i ont été déterminées pour chaque classe de grains, la densité de tassement virtuel (γ) de l'arrangement des grains peut être obtenue à partir de la relation suivante :

γ = la valeur la plus basse de toutes

$\gamma_i \neq 0$

et la valeur de chaque γ_i peut être calculée à l'aide de l'équation suivante:

$$\gamma_i = \frac{\beta_i}{1 - \sum_{j=1}^{i-1} \gamma_j \left(1 - \beta_i + b_{ij} \beta_i \left(1 - \frac{1}{\beta_j}\right)\right) \gamma_i - \sum_{j=i+1}^N \left(1 - a_{ij} \left(\frac{\beta_i}{\beta_j}\right)\right) \gamma_j} \quad \text{Eq. I. 20}$$

Dans l'équation précédente, γ_i correspond à la proportion massique de chaque classe de grains. La valeur de γ_i peut être obtenue à partir de la courbe de gradation de chaque matériau.

I.4.3.3.4 Le modèle d'empilement compressible (MEC)

Le modèle (MEC) représente la troisième version des modèles développés par LCPC. Ce modèle permet la prédiction de la compacité en fonction de la compacité propre de chaque fraction granulaire, la distribution granulométrique de chaque fraction et en fonction de l'énergie de compactage. Ce modèle se base sur les concepts de compacité virtuelle (γ) et l'indice de serrage (K) [3].

$$K = \sum_{i=1}^n \frac{\frac{\gamma_i}{\beta_i}}{C_{MEC} \gamma_i} \quad \text{Eq. I. 21}$$

Avec :

C_{MEC} : compacité réelle du mélange

K : indice de serrage pour le mélange

γ_i : compacité virtuelle lorsque la classe i est dominant.

n : nombre de classes dans le mélange

β_i : compacité virtuelle de classe i.

Le paramètre K dépend du processus de mise en place du mélange granulaire. C'est une fonction strictement croissante de C_{MEC} (Figure I. 17), ce qui montre qu'il existe bien, pour toute valeur positive de K, une valeur unique de C.

Pour un empilement de même taille, K prend la forme suivante :

$$K = \frac{1}{\frac{\beta_i}{\alpha_i} - 1} \quad \text{Eq. I. 22}$$




Figure I. 17 Deux classes granulaires avec le même diamètre [9].

➤ **Calibration du modèle**

Le modèle (MEC) a été validé est testé sur plusieurs mélanges granulaires binaire, ternaire avec des granulats concassés et roulés et avec une vibration sous charge de 10 kPa. A partir des résultats expérimentaux de Larrard propose deux équations pour déterminer les coefficients d'interaction.

$$a_{ij} = \sqrt{1 - \left(1 - \frac{d_j}{d_i}\right)^{1.02}} \quad \text{Eq. I. 23}$$

$$b_{ji} = 1 - \left(1 - \frac{d_i}{d_j}\right)^{1.50} \quad \text{Eq. I. 24}$$

Après la détermination des valeurs de a et b pour un indice de serrage K égale à 9, de Larrard a trouvé une bonne régression entre les résultats expérimentaux de la compacité et les résultats calculé par le MEC Figure I. 18 et Figure I. 19. Il a noté que le meilleur ajustement est obtenu par des granulats roulés avec une erreur absolue de 0.77% contre 1.71% pour de granulats concassés.

Tableau I. 4 Compacités des mélanges binaires. Grains roulés [18]

% fins	R8R05		R8R1		R4R05		R8R2		R2R05		R8R4		R1R05	
	Exp.	Théo.	Exp.	Théo.	Exp.	Théo.	Exp.	Théo.	Exp.	Théo.	Exp.	Théo.	Exp.	Théo.
0	0,628	0,632	0,628	0,632	0,6195	0,629	0,628	0,632	0,616	0,620	0,628	0,632	0,609	0,613
5	0,657	0,6557	0,6545	0,6526	0,645	0,6492	0,653	0,6481	0,635	0,6354	0,6375	0,6416	0,624	0,6217
10	0,6865	0,6808	0,6795	0,6743	0,6715	0,6703	0,682	0,6646	0,663	0,6512	0,643	0,6511	0,633	0,6304
15	0,710	0,7069	0,707	0,6966	0,689	0,692	0,697	0,6813	0,678	0,6667	0,654	0,6603	0,640	0,6386
20	0,729	0,733	0,724	0,7189	0,706	0,7136	0,714	0,7976	0,692	0,6826	0,660	0,6689	0,656	0,6462
25	0,754	0,7558	0,742	0,7391	0,7265	0,7326	0,7235	0,7122	0,708	0,6964	0,663	0,6762	0,666	0,6526
30	0,758	0,7877	0,748	0,7528	0,7785	0,7446	0,728	0,7229	0,718	0,7063	0,6595	0,6817	0,6705	0,6578
40	0,753	0,7544	0,7285	0,7496	0,736	0,7379	0,723	0,7251	0,708	0,7067	0,6565	0,6853	0,6635	0,659
50	0,7385	0,7256	0,7095	0,7277	0,725	0,7138	0,705	0,7111	0,693	0,6909	0,6535	0,6806	0,6545	0,6525
60	0,7165	0,6959	0,6965	0,7029	0,700	0,6875	0,689	0,6927	0,670	0,6709	0,649	0,6719	0,644	0,6421
70	0,680	0,6677	0,677	0,6786	0,6745	0,662	0,671	0,6737	0,656	0,6506	0,6445	0,6616	0,636	0,6303
80	0,652	0,6414	0,6585	0,6554	0,648	0,6379	0,646	0,6551	0,633	0,6308	0,638	0,6508	0,6215	0,6181
90	0,6195	0,6168	0,635	0,6336	0,614	0,6152	0,632	0,6361	0,613	0,6119	0,629	0,6398	0,610	0,6059
100	0,592	0,594	0,609	0,613	0,592	0,594	0,616	0,620	0,592	0,594	0,6195	0,629	0,592	0,594

Tableau I. 5 Compacités des mélanges binaires. Grains concassés [18]

% fins	C8C05		C8C1		C4C05		C8C2		C2C05		C8C4		C1C05	
	Exp.	Théo.	Exp.	Théo.	Exp.	Théo.	Exp.	Théo.	Exp.	Théo.	Exp.	Théo.	Exp.	Théo.
0	0,572	0,585	0,572	0,585	0,537	0,557	0,572	0,585	0,529	0,525	0,572	0,585	0,507	0,528
5	0,620	0,6066	0,613	0,6034	0,591	0,575	0,597	0,5986	0,54	0,5388	0,5825	0,5931	0,527	0,5362
10	0,642	0,6295	0,646	0,6226	0,6185	0,594	0,611	0,6125	0,552	0,5531	0,5875	0,6011	0,532	0,5444
15	0,676	0,6535	0,6755	0,6425	0,638	0,6137	0,625	0,6264	0,5515	0,5679	0,588	0,6087	0,545	0,5524
20	0,705	0,6779	0,699	0,6624	0,669	0,634	0,634	0,6398	0,566	0,583	0,592	0,6158	0,552	0,5602
25	0,731	0,7001	0,7215	0,6806	0,693	0,6536	0,643	0,6516	0,573	0,5979	0,5955	0,6217	0,5485	0,5673
30	0,7365	0,7135	0,7245	0,693	0,711	0,670	0,651	0,6594	0,594	0,6115	0,594	0,6259	0,555	0,5733
40	0,723	0,6998	0,7025	0,6861	0,691	0,6741	0,643	0,6554	0,588	0,626	0,5875	0,6271	0,556	0,5792
50	0,6941	0,6666	0,6705	0,6586	0,667	0,6502	0,6335	0,6349	0,582	0,617	0,587	0,6198	0,549	0,576
60	0,6585	0,6331	0,638	0,629	0,640	0,6219	0,6245	0,6111	0,579	0,5987	0,587	0,6084	0,546	0,5675
70	0,616	0,6019	0,611	0,6008	0,603	0,5945	0,5975	0,5877	0,568	0,5788	0,572	0,5956	0,5425	0,5567
80	0,583	0,5732	0,5965	0,5746	0,571	0,5688	0,5695	0,5654	0,5555	0,5493	0,564	0,5825	0,537	0,5455
90	0,5655	0,547	0,5435	0,5504	0,545	0,545	0,5435	0,5445	0,534	0,5406	0,553	0,5696	0,530	0,5341
100	0,516	0,523	0,507	0,528	0,516	0,523	0,529	0,525	0,516	0,523	0,5537	0,547	0,516	0,523

















Figure I. 18 Mélanges binaires des grains concassés. Compacité en fonction de la proportion de grains fins [9]

Figure I. 19 Mélanges binaires des grains concassés. Compacité en fonction de la proportion de grains fins [9]

Le modèle MEC a été validé expérimentalement à partir de différentes données réalisées ou tirées de la littérature. Dans le second cas pour un procédé de mise en place différent de celui proposé, l'indice de serrage K a été ajusté de tel façon d'avoir des meilleurs résultats. Le modèle a été testé avec succès sur une large gamme de mélanges granulaires binaire ternaires. de Larrard [3] a défini dans son travail des indices de compaction pour des différents procédés de mise en place

Tableau I. 6 indice de compaction K pour différents procédés de remplissage [18]

Procédé de remplissage	Déversement	Piquage avec une tige	Vibration	Pression statique	Vibration + pression 10kPa
Indice de compaction	4,1	4,5	4,75	7	9

De Larrard a testé des mélanges ternaires dans le même programme d'étalonnage. Après avoir arbitrairement sélectionné les classes <0,5, 1 et 8, les combinaisons les plus compactes ont été recherchées par essais expérimentaux successifs (Tableau I. 7). Ces mesures ont ensuite été simulées avec le Modèle d'Empilement Compressible, en prenant la valeur 9 pour K.

Tableau I. 7 Compacité mesuré (grains roulés et concassés) et prévision du modèle [18]

%R<05	%R1	%R8	C _{théo}	C _{exp}	%C<05	%C1	%C8	C _{théo}	C _{exp}
25	0	75	0,762	0,752	22	10	68	0,755	0,775
30	0	70	0,775	0,753	27	10	63	0,778	0,776
22	10	68	0,787	0,772	32	10	58	0,786	0,797
27	10	63	0,788	0,777	37	10	53	0,781	0,79
32	10	58	0,779	0,764	42	10	48	0,77	0,787
37	10	53	0,764	0,756	12	20	68	0,734	0,734
42	10	48	0,748	0,738	17	20	63	0,761	0,744
12	20	68	0,781	0,767	22	20	58	0,779	0,752
17	20	63	0,795	0,775	27	20	53	0,785	0,777
22	20	58	0,795	0,779	32	20	48	0,782	0,788
27	20	53	0,785	0,782	37	20	43	0,772	0,786
32	20	48	0,771	0,774	42	20	38	0,76	0,781
37	20	43	0,755	0,76	17	30	53	0,753	0,77
42	20	38	0,739	0,746	22	30	48	0,762	0,769
17	25	58	0,794	0,791	27	30	43	0,765	0,775
22	25	53	0,79	0,795	32	30	38	0,762	0,778
27	25	48	0,779	0,785	37	30	33	0,755	0,769
12	30	58	0,784	0,781	42	30	28	0,745	0,765
17	30	53	0,786	0,783	32	15	53	0,786	0,799
22	30	48	0,782	0,784					
27	30	43	0,771	0,776					
32	30	38	0,758	0,761					
37	30	33	0,743	0,747					
39	31,5	29,5	0,735	0,736					
17	35	48	0,776	0,772					
22	35	43	0,771	0,769					

Dans son investigation, de Larrard a mentionné la même tendance entre l'expérimentale et les résultats théoriques lors de l'utilisation des granulats concassés, avec une erreur moyenne supérieure à celle des granulats roulés, égales à 1,31%. Pour l'expérimentale, la valeur 0,7993 a été considérée comme la valeur optimale de la compacité pour le mélange 0,32/0,15/0,53. Pour le travail théorique la valeur optimale a été déterminée pour une valeur égale à 0,7854 pour les proportions 0,29/0,15/0,56 avec une erreur égale à 1,67%.).

I.5 Conclusion

Le présent chapitre, dans sa première partie, rapporte une synthèse sur les données des matériaux utilisés dans la réalisation des mélanges BCR pour barrages ainsi que leurs propriétés essentielles. De même, les propriétés des mélanges BCR à l'état frais et à l'état durci ont été analysées dans ce contexte. Les différentes informations recueillies se résument comme suit :

- Les mélanges BCR sont spécifiés par l'utilisation d'un mélange granulaire assez large variant d'éléments fin (fillers) aux gros grains ($D_{max} > 40$ mm), dans le but de remplir les vides intergranulaires et pour améliorer le degré de compactage.
- Les BCR nécessitent l'utilisation d'un faible dosage du ciment afin d'éviter les fissurations dues au dégagement de chaleur lors de l'hydratation du ciment.
- La bonne mise en œuvre du BCR est conditionnée par ses propriétés à l'état frais, notamment un temps VeBe entrant dans les plages recommandées,

Les propriétés mécaniques, thermiques et de durabilité demeurent des paramètres essentiels pour la stabilité du BCR en tant que matériau et des structures en BCR résultantes. Le deuxième volet de ce chapitre décrit les méthodes de formulations des mélanges BCR. D'après la littérature, les méthodes de formulation de BCR se regroupent en trois grandes catégories : des méthodes, empiriques, semi-empiriques et théoriques.

- Les méthodes de formulations conventionnelles des bétons ne sont pas appliquées directement au BCR à cause de ses spécificités tel que l'utilisation des fines et des ballasts > 40 mm, son faible dosage en liant et le mode de compaction.
- Les méthodes empiriques sont généralement basées sur un grand nombre de gâchages d'essais afin de définir une formulation optimale avec des caractéristiques désirées.
- Les méthodes de formulations semi-empiriques, sont basées à la fois sur des formules empiriques et des abaques et aussi sur un volume de gâchées d'essais au laboratoire afin d'atteindre des formulations de mélange BCR avec des performances souhaitées.
- La dernière catégorie de méthodes théoriques est basée essentiellement sur des formules empiriques en relation avec les caractéristiques des matériaux entrant dans la formulation du mélange, ces méthodes nécessitant la caractérisation expérimentale des matériaux constituant le mélange.

CHAPITRE II

*Techniques de l'intelligence
Artificielle et leur application dans le
domaine du béton*

II.1 Introduction

Les techniques d'intelligence artificielle (IA) ont pris de l'ampleur en offrant des approches informatiques alternatives pour résoudre des problèmes dans divers domaines. D'après Abdallah et al. [51] La technologie de l'IA traite de la conception de systèmes et de programmes informatiques capables d'imiter les traits humains tels que la résolution de problèmes, l'apprentissage, la perception, la compréhension, le raisonnement et la conscience de l'environnement. Yetilmezsoy et al. [52] note que les modèles d'IA tels que le réseau de neurones artificiels (RNA), le système expert, l'algorithme génétique (GA) et la logique floue (FL) ont la capacité de résoudre des problèmes, de configurer une cartographie complexe et de prédire les résultats. Konar [53] note que le terme "Intelligence Artificielle a été inventée par John McCarthy" et que les travaux de l'intelligence artificielle ont commencé après la seconde Guerre mondiale.

Ce chapitre présente deux techniques de l'intelligence artificielle, la première est les réseaux de neurones artificiels et la seconde méthode représente l'optimisation de l'essaim de particules. Ces deux méthodes ont été prises en considération dans les modèles de prédictions développées dans cette thématique de recherche.

II.2 Réseau de neurone artificiel (RNA)

II.2.1 Introduction et généralités

D'après John et al. [54] les réseaux de neurones artificiels sont devenus des outils indispensables pour résoudre des problèmes dans différents domaines. Boukhatem et al. [55] notent que les réseaux de neurones artificiels (RNA) ont montré des performances exceptionnelles en tant qu'outils utiles et puissants pour résoudre facilement des problèmes complexes et sont capables d'apprendre, de généraliser et d'optimiser des solutions à partir d'exemples et d'expériences sans aucune connaissance préalable de la nature de ces interactions.

Chakali et al. [56] décrivent que le fonctionnement du modèle informatique d'un réseau de neurone artificiel est inspiré de la structure et les interactions des neurones biologiques du cerveau humain. Le réseau de neurone artificiel est composé par des éléments de traitement appelés neurones. La connexion entre les neurones se réalise par des coefficients appelés (poids), ces connexions constituent la structure neuronale et des algorithmes d'entraînement sont liés à cette structure [57]. Vesanto [58] note que les réseaux de neurones sont appelés "modèles connexionnistes" en raison des connexions détectées entre les neurones. Chauhan et al. [59] décrivent les réseaux de neurones artificiels (RNA) comme un ensemble de techniques

mathématiques pouvant être utilisées pour le traitement des signaux, la prévision et l'on parle de techniques de régression parallèle, non linéaire et à plusieurs niveaux. Ji et al. [60] notent que l'avantage principale de l'utilisation des réseaux de neurones est que l'utilisateur utilise le RNA sans assomptions de la forme du modèle, qui est une condition préalable à l'approche paramétrique.

Il existe différents types de RNA dans la littérature, notamment le réseau neuronal Spiking [61], le réseau Feedforward [62], le réseau neuronal récurrent [63], le réseau de fonction de base radiale [64] et le réseau d'auto-organisation de Kohonen [64].

L'architecture RNA se compose de trois parties : une couche d'entrée qui est un vecteur des entrées, la couche (s) intermédiaire (s) (cachée) qui est la partie principale de l'architecture RNA, dont chaque couche cachée contient une collection de neurones, et la dernière partie est la couche de sortie qui est responsable de la production du résultat. Un réseau neuronal ne doit avoir qu'une seule couche d'entrée et une seule couche de sortie. Les neurones, à l'intérieur de chaque couche, remplissent un même rôle. Le neurone dans les RNA est une unité de traitement de l'information, qui forme la base de la conception d'une grande famille de réseaux neuronaux [65]. Kouzi [66] note que les réseaux de neurones ont l'aptitude de mémoriser de la connaissance obtenue par un processus d'apprentissage dans les poids synaptiques. Le nombre de neurone dans chaque couche est choisi de tel façon à atteindre de meilleurs résultats pour résoudre le problème. Le nombre de couche cachées est souhaitée d'être optimal afin d'avoir des meilleures performances et de minimiser le temps de calcul. Haykin [67] note que le réseaux de neurone artificielle ressemble au cerveaux humain sur deux apparences:

- ✓ La connaissance de l'information se fait par un processus d'apprentissage.
- ✓ La connexion entre les neurones se fait à travers des coefficients appelée poids synaptiques qu'il servent à mémoriser la connaissance.

II.2.2 Neurone artificiel (formel)

Dreyfus [68] note que le neurone représente une fonction non linéaire, paramétrée, à valeurs bornées. McCulloch et Pitts [69] ont présenté le réseau de neurone artificiel pour la première fois en 1943, ils ont simulé le fonctionnement du cerveau humain comme un ordinateur bien défini et structuré ayant une infinité de neurones.

Les neurones sont les entités de base dans lesquelles ils sont des cellules qui créent des relations entre eux en formant des réseaux. En fait, le raisonnement est effectué dans les cellules en

utilisant les informations provenant des messages d'entrées ou d'autres réponses de sorties des neurones via une fonction d'activation, un modèle mathématique d'un comportement neuronal.

II.2.3 Concepts de base

Les neurones calculent la somme pondérée des entrées dans la couche d'entrée et les poids, ajoutent le biais et exécutent une fonction d'activation pour fournir la sortie. Les neurones sont reliés par des liens par lesquels ils interagissent, et chaque lien est associé à un poids qui sera modifié en fonction des résultats. Les résultats sont transmis à d'autres neurones et les valeurs envoyées diffèrent de celles reçues en fonction de ces poids. Le poids est la valeur qui est multipliée par la valeur portée avant de transmettre le résultat au neurone suivant. Les poids des neurones sont des variables de conception à modifier. Un autre paramètre qui peut améliorer les performances du réseau neuronal est un terme de biais qui est inclus dans chaque neurone dans les couches cachées et de sorties [70]

La Figure II. 1 représente un neurone biologique et un modèle simple de neurones de réseaux neuronaux artificiel de type perceptron [71]




Figure II. 1 Représentation (a) d'un réseau neuronal biologique et (b) d'un réseau neuronal artificiel de type Perceptron.

L'entrainement du RNA se fait à travers les entrées et les sorties de la base de données, cet entrainement nécessite un processus d'apprentissage qu'il se traduit sur l'utilisation d'un algorithme permet au RNA de créer une fonction qui relie les entrées et les sorties de la base de

données. Les neurones de la couche d'entrée reçoivent les données attribuées pour chaque neurone ($x_1, x_2 \dots x_i$). Par la suite, les données de la couche d'entrée seront transférées aux neurones de la couche cachée par des liaisons pondérées sous forme de poids ($w_1, w_2 \dots w_i$) et la comparer avec un seuil b_k . Les équations ci-dessous (Eq. II. 1) et (Eq. II. 2) représentent le principe de calcul dans les neurones.

$$y_i = f(net_j) \quad \text{Eq. II. 1}$$

$$net_j = \sum_i w_i x_i + b_k \quad \text{Eq. II. 2}$$

Où : y_i et x_i représentent les variables de sortie et d'entrée respectivement, b_k représente le seuil d'activation (biais) du neurone, w_i est le poids synaptique d'un neurone i de la couche d'entrée. L'état des neurones de la couche cachée est déterminée par une fonction d'activation $f(x)$ qui limite les valeurs de sortie pour chaque neurone par les bornes minimales et maximales attribuées. Pour un réseau de neurones fiables, il est important de choisir le type de la fonction d'activation associée au neurone de la couche cachée. Ensuite les valeurs des neurones de la couche cachée sont transmises de la même manière à la seconde couche jusqu'à l'arrivée de la couche de sortie, à la fin et aux neurones de la couche de sortie les valeurs de sorties (y_k) sont produites. La valeur d'erreur finale représente la différence entre les valeurs de sorties prédit par le RNA et ceux de la base de données. D'après Boukhatem et al. [72] le processus d'apprentissage se fait par des étirassions et il s'arrête pour des résultats d'erreurs acceptables entre les valeurs introduites et prédites.

Dans le RNA, plusieurs fonctions d'activation de neurones ont été proposés. Généralement les fonctions "sigmoïdes", "linéaire" et "seuil" sont les plus connues et utilisées (Figure II. 2) [5].




Figure II. 2 Type des fonctions d'activation : (a) Linéaire ; (b) Tan-Sigmoïde ; (c) Log-Sigmoïde

II.2.4 Réseaux de neurones "FEED-FORWARD"

Les réseaux neuronaux supervisés typiques sont appelés feedforward, et sont basés sur le modèle du perceptron [73,74]. Dans un réseau neuronal feedforward, chaque neurone de la première couche détecte une valeur réelle d'entrée, la multiplie par un poids et transmet le résultat à tous les neurones de la couche suivante. Dans les représentations courantes des réseaux neuronaux, les scientifiques considèrent la couche la plus à gauche comme la première couche et la couche la plus à droite comme la couche de sortie (Figure II. 3). Les neurones de chaque couche au-delà de la couche d'entrée font le même travail et envoient les résultats aux neurones de la couche suivante, jusqu'à la couche finale (le processus va de gauche à droite). Dans un réseau neuronal supervisé, la couche finale envoie ensuite ses résultats à une couche de sortie à un neurone qui produit le résultat à une valeur réelle du réseau neuronal (Figure II. 3).




Figure II. 3 Représentation de la structure du modèle de réseau de neurones FEED-FORWARD [59].

Pendant la formation, le réseau de neurones compare les valeurs produites par le réseau de neurones avec sa vérité de base correspondante, et calcule l'erreur statistique (généralement l'erreur quadratique moyenne ou l'erreur d'entropie croisée). Ensuite, le réseau neuronal renvoie l'erreur aux couches précédentes et met à jour les poids de ses neurones en conséquence, par une technique appelée rétropropagation de l'erreur [6]. Dans La représentation des termes, la rétropropagation se fait de droite à gauche (Figure II. 3). La formation s'arrête lorsque le réseau neuronal atteint le nombre maximal d'itérations initialement fixé. Une fois le modèle formé, il

peut alors être appliqué à l'ensemble de test : le réseau neuronal traitera chaque instance de données de test (une seule fois, de la première couche à gauche à la dernière couche à droite) et générera une valeur prédite. Une fois que le réseau neuronal a généré une valeur prédite pour chaque instance de l'ensemble de test, le programmeur peut l'utiliser pour calculer une matrice de confusion.

Les réseaux neuronaux à action directe avec rétropropagation des erreurs sont également utilisés dans les réseaux neuronaux siamois. L'architecture des réseaux de neurones siamois contient en fait deux réseaux de neurones à action directe identiques, reliés à leur sortie (Figure II. 3), qui fonctionnent en tandem. Chaque réseau de neurones contient un modèle de perception traditionnel [57]. Pendant la formation, chaque réseau neuronal lit un profil composé de valeurs réelles et traite ses valeurs à chaque couche. Le réseau neuronal active certains des neurones en fonction de ces valeurs, met à jour ses poids par rétropropagation des erreurs [6] et génère à la fin un profil de sortie qui est comparé à la sortie de l'autre réseau neuronal.

L'algorithme compare les sorties du réseau neuronal supérieur et neuronal inférieur à l'aide d'une métrique de distance (Figure II. 3) : une distance cosinusoïdale dans le modèle original [75].

Grâce à cette mesure de similarité, le réseau neuronal indique que les deux profils sont différents (valeur de similarité du cosinus dans l'intervalle $[0, 1]$) ou similaires (valeur de similarité du cosinus dans l'intervalle $[0, +1]$). L'algorithme désigne alors l'instance de données comme positive dans le premier cas, ou négative dans le second. La valeur finale de la sortie peut finalement être comparée à sa valeur de vérité de base correspondante ; toutes les sorties classées peuvent être utilisées pour générer une matrice de confusion.

Un perceptron multicouche composé de trois couches est représentée par l'Eq. II. 3 et l'Eq. II. 4 :

$$y_i = f(net_j) \quad \text{Eq. II. 3}$$

$$net_j = \sum_i w_{ji} x_i + b_j \quad \text{Eq. II. 4}$$

Où : x_i représente la sortie de la valeur entrée et y_i les couches cachées.

w_{ji} et θ_i ce sont le poids et le biais respectivement entre la couche d'entrée et la couche caché.

L'Eq. II. 5 et l'Eq. II. 6 sont les opérations de la couche de sortie, Ils utilisent les y_i ; la valeur de sortie de la couche cachée.

$$z_k = f(\text{net}_k) \quad \text{Eq. II. 5}$$

$$\text{net}_k = \sum_k w_{kj} x_j + b_k \quad \text{Eq. II. 6}$$

Où : Z_k représente la valeur calculée du réseau de neurones.

W_{kj} et θ_k représente à la fois le poids et le biais entre le $K^{\text{ième}}$ neurone de la couche de sortie.

L'erreur « E » définie dans l'Eq. II. 7 représente la différence entre la valeur de sortie calculée Z_k et la valeur de sortie désirée d_k

$$E = \frac{1}{2} \sum_k (d_k - z_k)^2 \quad \text{Eq. II. 7}$$

II.2.5 Apprentissage

L'apprentissage chez les humains et les animaux représente une procédure de réalisation d'une manière autonome une tâche donnée. Par exemple, l'apprendre chez les enfants se fait par leur présentés des exemples de chiffre et de lettre avec différents styles en plusieurs fois. À la fin de l'apprentissage, on attend que l'enfant soit capable de lire non seulement tous les chiffres et lettres qui lui ont été présentés durant son apprentissage, mais également tous les chiffres et lettres qu'il est susceptible de rencontrer : en d'autres termes, on attend de lui qu'il ait une capacité de généralisation à partir des exemples qui lui ont été présentés. L'apprentissage numérique poursuit exactement le même objectif, il s'agit de faire en sorte, à l'aide d'une procédure numérique programmée et exécutée sur un ordinateur, d'inférer un modèle d'un processus que l'on observe et sur lequel on peut effectuer des mesures [76].

Mordjaoui [77] note que l'apprentissage dans un réseau de neurone représente un processus dynamique et itératif permettant de modifier les paramètres du (RNA) en fonction des entrées et des sorties attribuées.

II.2.5.1 Algorithme d'apprentissage et principe

Dans le RNA, il existe plusieurs algorithmes d'apprentissage, l'algorithme de rétropropagation est considéré comme le plus utilisé. D'après Yang et al. [78] dans un RNA, la transmission du signal d'apprentissage se fait à partir de la couche d'entrée vers la couche cachée ensuite vers la couche de sortie, l'erreur minimale sera atteinte avec la répétitions itérative du processus d'apprentissage. D'après Rebouh [79] l'algorithme de rétropropagation passe par six étapes essentiels:

- **Etape 1** : Cette étape représente l'initialisation des paramètres principales ; les poids (W_{kj} , W_{ij}), les biais (b_i , b_k) ainsi que le taux d'apprentissage (η) et le Momentum (α).
- **Etape 2** : Cette étape représente le calcul de l'erreur généralisée δ_k

$$\delta_k = Z_k (1 - Z_k) (d_k - Z_k)$$

- **Etape 03** : ajustement des poids entre la couche cachée et la couche de sortie

$$\Delta W_{kj} (K+1) = \eta \delta_k y_j + \alpha W_{kj} (k)$$

- **Etape 04** : calcul de l'erreur généralisée de la couche cachée

$$\delta_j = y_j (1 - y_j) + \sum_k \delta_k W_{kj}$$

- **Etape 05** : ajustement des poids entre la couche cachée et la couche de sortie

$$\Delta W (K+1) = \eta \delta_j y_i + \alpha W_{ji} (k)$$

- **Etape 06** : répétition des étapes de 1 à 5 jusqu'à atteindre la valeur d'erreur désirée.

II.2.5.2 Types d'apprentissage

Les algorithmes d'apprentissage peuvent être classés comme suit : algorithmes supervisés et non supervisés, algorithmes paramétriques et non paramétriques, algorithmes probabilistes, ou algorithmes univariés et multivariés [80].

Les types d'algorithmes d'apprentissage ont été définis par Ponce-Espinosa et al. [80] comme suite :

II.2.5.2.1 Algorithmes d'apprentissage supervisé et non supervisé

Désignons par $\Sigma = (X, Y)$ tout système Σ donné avec des paires ordonnées (X, Y) d'observations de variables attributaires et cibles, respectivement. Les algorithmes d'apprentissage supervisés construisent un modèle $M\Sigma$ d'un système Σ à l'aide de données ou d'expériences passées et

présentes sous la forme de paires ordonnées de variables d'attributs et de variables cibles, également appelées entrées et sorties. L'idée derrière ces algorithmes est de minimiser toute métrique qui mesure la distance entre les observations cibles et le modèle. Cette métrique est connue sous le nom de fonction de perte ou fonction d'erreur E , et mesure la précision du modèle par rapport aux données cibles. Dans les procédures d'optimisation, cette fonction de perte est appelée fonction objective. En fait, la métrique la plus courante est la fonction de perte dite au carré comme (Eq. II. 8) ; où, q est le nombre d'observations de données (échantillons), $x_k \in \mathbb{R}^n$ est le k -ième échantillon de variables d'attribut $x_1, \dots, x_n \in X$, $y_k \in \mathbb{R}^m$ est le k -ième échantillon de variables cibles $y_1, \dots, y_m \in Y$ et $M_\Sigma(x_k)$ est la réponse du modèle due à x_k .

$$E = \frac{1}{2} \sum_{k=1}^q (y_k - M_\Sigma(x_k))^2 \quad \text{Eq. II. 8}$$

En revanche, les algorithmes d'apprentissage non supervisé construisent des modèles M_Σ d'un système Σ uniquement à l'aide de variables attributaires X . Ces processus d'apprentissage reconnaissent les régularités dans le domaine d'entrée du système. Différentes métriques sont largement utilisées, mais une fonction de perte au carré E peut être calculée comme (Eq. II. 9) ; où, q est le nombre d'échantillons d'entrée, $x_k \in \mathbb{R}^n$ est le k -ième échantillon de variables d'attributs $x_1, \dots, x_n \in X$ et θ_i est un ensemble de paramètres définis dans le modèle.

$$E = \frac{1}{2} \sum_{k=1}^q (x_k - \theta_i)^2 \quad \text{Eq. II. 9}$$

II.2.5.2.2 Algorithmes d'apprentissage paramétrique et non paramétrique

D'une part, les algorithmes d'apprentissage paramétrique construisent un modèle M_Σ qui dépend de paramètres appropriés θ_i , tels que, $M_\Sigma(X|\theta_i)$. En fait, les algorithmes d'apprentissage paramétrique sont réduits à un problème d'optimisation dans lequel l'ensemble des paramètres optimaux θ_i satisfait la minimisation de E dans (Eq. II. 8) ou (Eq. II. 9). Les types d'algorithmes les plus connus pour les modèles continus relèvent des méthodes de régression, et de ses variantes, comme la régression linéaire, la régression quadratique ou la régression polynomiale. Par exemple, l'algorithme des réseaux d'hydrocarbures artificiels utilise la méthode bien connue des estimations des moindres carrés, une technique de régression, comme algorithme d'apprentissage supervisé et paramétrique pour trouver les paramètres appropriés en son sein.

D'autre part, les algorithmes d'apprentissage non paramétrique construisent un modèle $M\Sigma$ qui ne dépend que des observations de données du système, tel que, $M\Sigma(X)$. En fait, les algorithmes d'apprentissage non paramétrique supposent des similarités dans les données d'entrée. Ainsi, des entrées similaires peuvent avoir des sorties similaires. Dans ce cas, ces méthodes sont également appelées lisseurs. Les algorithmes les plus courants sont le lisseur à moyenne mobile, le lisseur à noyau et le lisseur à ligne mobile. Chacun d'entre eux déduit le modèle $M\Sigma(X)$ en termes de mesures relatives parmi les échantillons de X afin de minimiser (Eq. II. 8).

II.2.5.2.3 Algorithmes d'apprentissage probabilistes

Les algorithmes d'apprentissage probabilistes prétendent à l'incertitude dans les observations des données d'entrée-sortie (X,Y) . Dans ce cas, un modèle est construit en termes de dépendances d'unités d'information qui sont liées avec une probabilité conditionnelle en raison de la règle de Bayes. Les algorithmes typiques font références aux algorithmes de décision bayésiens, tels que les réseaux bayésiens ou les réseaux de croyance. L'estimation du maximum de vraisemblance et le modèle de biais et de variance sont d'autres algorithmes d'apprentissage utilisant des probabilités.

II.2.5.2.4 Algorithmes d'apprentissage univariés et multivariés

Les algorithmes d'apprentissage univariés construisent des modèles qui ne dépendent que d'une variable attributaire $x \in X$ alors que les algorithmes d'apprentissage multivariés construisent des modèles qui dépendent de plusieurs variables attributaires $x_1, \dots, x_n \in X$. Dans les applications du monde réel, les algorithmes d'apprentissage multivariés sont préférés plus que les univariés car les systèmes complexes dépendent de plusieurs variables d'entrée.

II.2.6 Avantage et limites des réseaux de neurones artificiels (RNA)

Comme chaque système, les RNA ont des avantages et des limites d'utilisation

- **Avantages des réseaux de neurones artificiels (RNA)**
 - Stockage des données sur l'ensemble du réseau : les informations telles que dans la programmation traditionnelle sont stockées sur l'ensemble du réseau et non sur une base de données.
 - Aptitude à fonctionner avec des connaissances incomplètes : après la création du RNA, le réseau peut produire des conséquences même avec des données incomplètes. La perte de précision du RNA dépend de l'importance des informations absentes.

- Possession d'une tolérance aux problèmes : le manque d'une ou de plusieurs données du RNA ne l'empêche pas de prédire une sortie. Cette activité remet les RNA résistant aux pannes.
 - Possède d'une mémoire distribuée : Pour qu'un RNA puisse apprendre, il est essentiel de déterminer les exemples et d'enseigner le RNA en relation de la sortie désirée. Le succès du réseau est directement proportionnel aux instances sélectionnées, et si l'événement ne peut pas être montré au réseau sous tous ses aspects, le réseau peut produire une fausse sortie
 - L'aptitude à faire de l'apprentissage automatique : les RNA apprennent les événements et prennent des décisions en commentant des événements similaires.
 - Capacité de traitement parallèle : les réseaux de neurones artificiels ont une force numérique qui peut effectuer plus d'un travail en même temps.
- **Inconvénients des réseaux de neurones artificiels (RNA)**
- Dépendance matérielle : les RNA nécessitent des processeurs avec une puissance de traitement parallèle, conformément à leur structure. Pour cette raison, la réalisation de l'équipement est dépendante.
 - Comportement inexplicé du réseau : C'est le problème le plus important du RNA. Lorsque RNA produit une solution de sondage, cela ne donne aucune idée du pourquoi et du comment. Cela réduit la confiance dans le réseau.
 - Détermination de la structure de réseau appropriée : Il n'y a pas de règle spécifique pour déterminer la structure des RNA. Une structure de réseau appropriée est obtenue grâce à l'expérience et aux essais et erreurs.
 - Difficulté à montrer le problème au réseau : les RNA peuvent apprendre avec des informations numériques. Les problèmes doivent être expliqués en valeurs numériques avant d'être introduits dans RNA. Le mécanisme d'affichage à déterminer ici influencera directement les performances du réseau. Cela dépend de la capacité de l'utilisateur.
 - La durée du RNA est inconnue : Le RNA est réduit à une certaine valeur de l'erreur sur l'échantillon signifie que la formation est terminée. Cette valeur ne nous donne pas des résultats optimaux.

Les réseaux de neurones artificiels scientifiques qui sont apparus dans le monde au milieu du XXe siècle se développent rapidement. De nos jours, nous avons examiné les avantages des réseaux de neurones artificiels et les problèmes rencontrés au cours de leur utilisation. Il ne faut

pas oublier que les inconvénients des réseaux RNA, qui sont une branche scientifique en développement, sont éliminés un à un et que leurs avantages augmentent de jour en jour. Cela signifie que les réseaux de neurones artificiels deviennent une partie indispensable de la vie courante.

II.3 Essaims de particules

II.3.1 Introduction et historique

Les applications des algorithmes de recherche métaheuristiques inspirés par des phénomènes naturels se développent rapidement dans divers domaines scientifiques pour résoudre des problèmes d'optimisation difficiles. Parmi les algorithmes d'optimisation stochastique les plus populaires, citons les algorithmes génétiques (AG) inspirés de l'évolution darwinienne et de la sélection naturelle des systèmes biologiques [81], le recuit simulé (SA) inspiré du processus de recuit des métaux [82], l'optimisation par colonies de fourmis (ACO) modélisée par les actions d'une colonie de fourmis [83], l'optimisation par essaims de particules (PSO) inspirée du comportement des oiseaux [84], et la recherche d'harmonie (HS) inspirée du processus d'improvisation des musiciens [85]. Il s'agit d'algorithmes approximatifs qui explorent efficacement l'espace de recherche afin d'aboutir à des solutions quasi-optimales en un temps raisonnable.

Les algorithmes de recherche métaheuristiques inspirés de la nature attirent également de plus en plus l'attention de la communauté des chercheurs en génie civil en raison de leur capacité à résoudre un large éventail de problèmes d'optimisation continus, discrets et combinatoires, tout en étant faciles à mettre en œuvre [86,87]. Puisqu'ils ne sont pas spécifiques au problème, qu'ils n'exigent pas que la fonction objective soit continue ou différentiable (contrairement aux algorithmes d'optimisation basés sur le gradient comme la méthode quasi-Newton), qu'ils peuvent incorporer des contraintes, qu'ils peuvent rechercher de très grands espaces de solutions candidates et qu'ils sont en général parallélisables. Les chercheurs les appliquent avec succès à une diversité de problèmes d'optimisation en génie civil. L'objectif de cette étude est de fournir un aperçu de l'état de l'art des applications PSO rapportées dans la littérature de génie civil entre 1995 et 2010.

PSO est un outil d'optimisation globale basé sur la population, appartenant à la classe des techniques d'intelligence artificielle (SI), qui a été développé en 1995 et est basé sur les comportements d'essaimage observés dans les volées d'oiseaux ou les bancs de poissons [84,88]. PSO a très peu de paramètres à ajuster, peut être mis en œuvre en quelques lignes de

code informatique et, sans aucune variation ou avec de légères variations, fonctionne bien dans une grande variété d'applications, y compris dans des domaines tels que le traitement du signal, les graphiques, la robotique, et ainsi de suite [87].

II.3.2 Définition, inspiration et principe de fonctionnement

Le concept de PSO introduit par Eberhart et Kennedy [84] s'inspire de la vie artificielle, du vol d'oiseaux, de l'élevage de poissons, de la théorie de l'essaimage, ainsi que de l'AG et de la programmation évolutive. Bien qu'il ait été introduit à l'origine pour l'optimisation de fonctions continues non linéaires, de nombreux progrès dans le développement du PSO lui ont permis de traiter une large classe de problèmes complexes d'optimisation en ingénierie et en sciences.

Le PSO utilise une population de solutions potentielles au problème considéré pour explorer l'espace de recherche. Cependant, chaque individu de la population dans PSO a une vitesse adaptable (changement de position), en fonction de laquelle il se déplace dans l'espace de recherche. De plus, chaque individu possède une mémoire qui se souvient de la meilleure position de l'espace de recherche qu'il a déjà visitée [89]. Le mouvement de l'individu est donc une accélération agrégée vers sa meilleure position précédemment visitée et vers le meilleur individu d'un voisinage topologique. Comme le terme "accélération" était principalement utilisé pour les systèmes de particules en physique des particules [90] et le terme "essaim" pour décrire la population, cet algorithme a été nommé PSO. Essentiellement, PSO emploie un essaim de particules ou de solutions possibles qui volent dans l'espace des solutions réalisables pour explorer les solutions optimales.

Deux variantes de l'algorithme PSO ont été développées à l'origine : une avec un voisinage global (modèle Gbest) et une avec un voisinage local. Chaque particule se déplace vers sa meilleure position précédente et vers la meilleure particule de l'ensemble de l'essaim, selon la variante globale. En revanche, chaque particule se déplace vers sa meilleure position précédente et vers la meilleure particule de son voisinage restreint, selon la variante locale [84]

L'algorithme PSO à variante globale, qui est le plus standard, est décrit comme suit. Supposons que l'espace de recherche soit à D dimensions, alors la i ème particule de l'essaim peut être représentée par un vecteur à D dimensions, X_i ($x_{i1}, x_{i2}, \dots, x_{iD}$)

La vitesse (changement de position) de cette particule peut être représentée par un autre vecteur à D dimensions V_i ($v_{i1}, v_{i2}, \dots, v_{iD}$)^T. La meilleure position précédemment visitée de la i ème particule est désignée par P_i ($p_{i1}, p_{i2}, \dots, p_{iD}$)^T. En définissant g comme l'indice de la

meilleure particule de l'essaim, et les exposants indiquent le nombre d'itérations. Chaque particule met à jour sa position en fonction de sa propre meilleure exploration, de la meilleure expérience globale de l'essaim et de son vecteur de vitesse précédent selon les deux équations suivantes [84] qui définissent la version initiale de l'algorithme PSO :

$$v_{id}^{n+1} = v_{id}^n + cr_1^n(p_{id}^n - v_{id}^n) + cr_2^n(p_{gd}^n - x_{id}^n) \quad \text{Eq. II. 10}$$

$$x_{id}^{n+1} = x_i^d + v_{id}^{n+1} \quad \text{Eq. II. 11}$$

Où $d = 1, 2, D$; $i \in 1, 2, N$ et N est la taille de l'essaim ; c c'est une constante positive appelée constante d'accélération ; r_1 et r_2 sont des nombres aléatoires, uniformément répartis dans $[0, 1]$; et $n \in 1, 2, \dots$, détermine le nombre d'itérations. La performance de chaque particule est mesurée en fonction d'une fonction de fitness ou d'une fonction objective prédéfinie, qui est liée au problème considéré.

Par la suite, un paramètre de vitesse maximale, V_{max} , a été imposé pour améliorer l'efficacité de PSO dans la région de l'optimum en permettant à son pas de vitesse de poursuivre la recherche à un grain plus fin. Ainsi, dans les versions ultérieures du PSO, les équations (Eq. II. 10) et (Eq. II. 11) ont été modifiées comme suit en incorporant un paramètre de poids pour la vitesse antérieure de la particule [91]:

$$v_{id}^{n+1} = wv_{id}^n + c_1r_1^n(p_{id}^n - x_{id}^n) + c_2r_2^n(p_{gd}^n - x_{id}^n) \quad \text{Eq. II. 12}$$

$$x_{id}^{n+1} = x_i^d + v_{id}^{n+1} \quad \text{Eq. II. 13}$$

Où w est appelé poids d'inertie ; c_1 et c_2 sont deux constantes positives appelées respectivement paramètres cognitifs et sociaux ; et χ est un facteur de constriction.

Cognitifs et sociaux, respectivement ; et χ est un facteur de constriction, qui est utilisé, à la place de w , pour limiter la vélocité. la Figure II. 4 schématisant le mécanisme d'optimisation.




Figure II. 4 Mécanisme de recherche de l'optimisation par essaims de particules

Le critère de terminaison pour PSO est généralement l'un des suivants : (i) mettre fin au processus d'optimisation après un nombre fixe d'itérations même si la convergence n'est pas atteinte, (ii) mettre fin à l'optimisation après un nombre fixe d'itérations sans amélioration de la solution, et (iii) prédéfinir une tolérance d'erreur et mettre fin à l'optimisation si l'erreur entre la valeur de la fonction objectif et la meilleure valeur de fitness est inférieure à la tolérance d'erreur [92]

Le comportement de l'essaim dans le PSO conventionnel est influencé par le nombre de particules, le poids d'inertie, la vitesse maximale et les coefficients d'accélération pour modifier la vitesse. Le choix des paramètres de l'algorithme PSO est considéré comme étant de la plus haute importance pour la vitesse, la convergence et l'efficacité de l'algorithme. L'impact de l'historique des vitesses précédentes sur la vitesse actuelle est contrôlé par l'utilisation du poids d'inertie, w , qui influe sur le compromis entre le global (grande portée) et le local (petite portée). La capacité d'exploration globale (recherche de nouvelles zones) est facilitée par un poids d'inertie plus important, tandis qu'un poids d'inertie plus faible tend à faciliter l'exploration locale pour affiner la zone de recherche actuelle. Ainsi, un bon équilibre entre les capacités d'exploration globale et locale, nécessitant moins d'itérations en moyenne pour opter pour la solution optimale, peut être obtenue par une sélection appropriée du poids d'inertie [91]

Le PSO ne nécessite que des opérateurs mathématiques primitifs, car il n'implique que deux équations de modèle et est peu coûteux en termes de mémoire et de vitesse. Il présente plusieurs

avantages par rapport à d'autres techniques d'optimisation, notamment [93] sa nature sans dérivation, contrairement à de nombreuses techniques conventionnelles, sa souplesse d'intégration avec d'autres techniques d'optimisation et d'informatique douce pour former des outils hybrides, le nombre réduit de paramètres à ajuster, sa capacité à traiter des fonctions objectives de nature stochastique, sa facilité de mise en œuvre, l'absence d'exigence de solution de départ pour lancer son processus d'itération.

Depuis son développement initial en 1995, il y a eu plus de 20 variantes différentes de PSO dérivées principalement en modifiant la façon dont la vitesse d'une particule est mise à jour pour améliorer la performance de PSO. Ces variantes comprennent PSO discret (DPSO), PSO unifié (UPSO), PSO chaotique (C-PSO), et ainsi de suite [94]

Les applications PSO rapportées dans différentes branches du génie civil sont résumées dans les sections suivantes après une brève mise en garde. Selon le théorème no-free-lunch (NFLT) de Wolpert et Macready [95], toutes les méthodes d'optimisation ont des performances égales lorsqu'on en réalise la moyenne sur tous les problèmes.

II.4 System hybrid d'essaims de particules réseau de neurones artificiels (RNA-PSO)

II.4.1 Technique d'hybridation

L'efficacité des RNA repose sur l'optimisation des paramètres du réseau (poids et biais), ce qui se fait par des algorithmes d'apprentissages qui sont limités en cas de problème complexe et rendent le processus d'apprentissage relativement lent [96]. Afin d'optimiser au mieux le modèle RNA, un système hybride RNA-PSO a été développé pour optimiser les poids (W) et des biais (b) du RNA.

La Figure II. 5 explique les étapes du fonctionnement du modèle proposé. Chaque ensemble de poids et de biais du RNA est considérée comme une particule de l'essaim du PSO. Au début, les particules seront initialisées de manière aléatoire, chaque particule étant représentée par une position donnée X_i dans le domaine de recherche des particules. Ensuite, pour chaque nouvelle génération, les positions et les vitesses seront mises à jour. Selon la fonction « fitness » de RNA, les paramètres p_{id}^n et p_{gd}^n sont corrigés et les positions finales des particules seront obtenues par une actualisation des équations 2 et 3 jusqu'à l'obtention des valeurs optimales des paramètres du RNA.

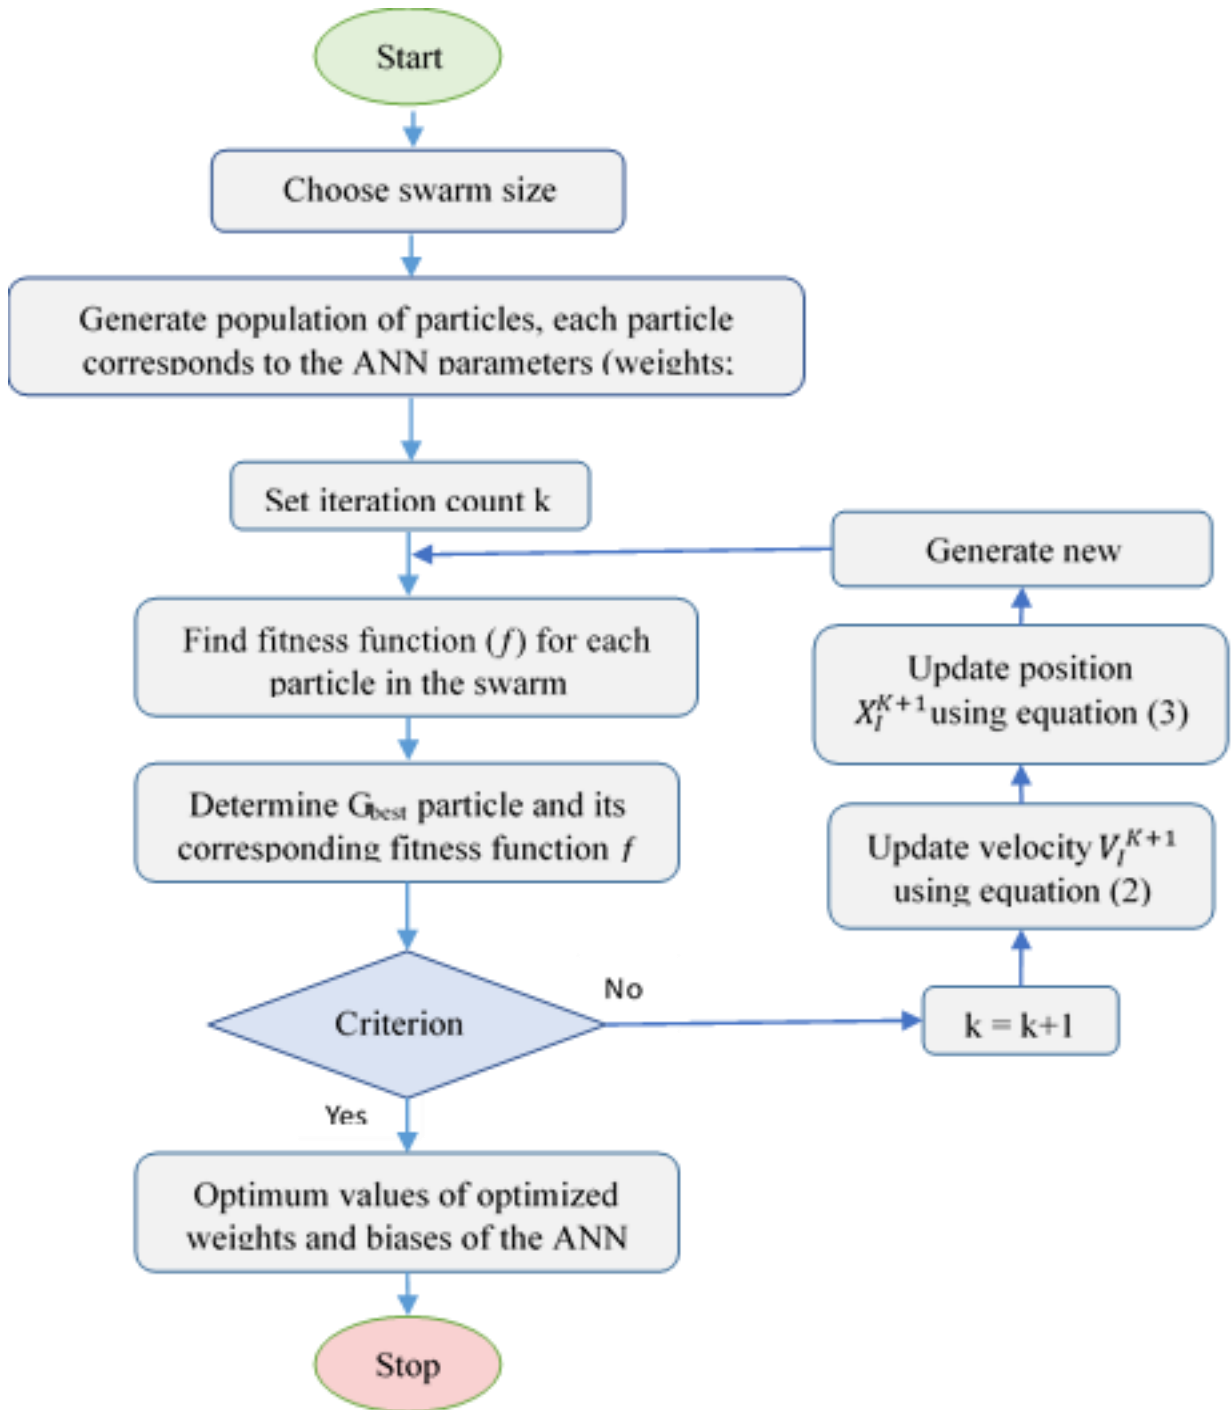


Figure II. 5 Organigramme du modèle RNA-PSO.

II.5 Application de l'intelligence Artificielle dans le domaine du béton

II.5.1 Introduction

Les développements rapides de nouveaux types de béton stimulés par les exigences de l'industrie de la construction ont motivé diverses recherches pour développer de nouveaux modèles prédictifs capables d'estimer les propriétés du béton. La prédiction des propriétés mécaniques du béton a été une tâche de recherche importante qui pourrait mieux répondre aux exigences de divers codes et normes de conception. Les modèles conventionnels de prévision des propriétés mécaniques, rhéologiques, de durabilité et autres du béton consistaient essentiellement en des relations empiriques développées à partir de l'analyse statistique de données expérimentales, où des modèles de régression linéaire et non linéaire ont été établis [97,98] . Dans la littérature ouverte, des modèles de régression ont été suggérés pour estimer les propriétés mécaniques du béton, y compris la résistance à la compression, la résistance à la traction, la résistance au cisaillement et le module d'élasticité [99–104].

Même si ces modèles se sont avérés efficaces dans certains cas et ont tendance à faire gagner du temps et des coûts pour les applications futures, leur développement est associé à de multiples inconvénients. Les lots d'essais coûteux et chronophages nécessaires pour établir des modèles empiriques font partie de leurs principales lacunes. De plus, les modèles conventionnels fonctionnent mal dans le traitement des matériaux complexes [105], ce qui les rend peu fiables pour estimer les propriétés de plusieurs types de béton.

Pour compenser les inconvénients des modèles de régression linéaires et non linéaires conventionnels, les techniques de IA ont été récemment introduites comme un concurrent sérieux pour la prédiction de la résistance mécanique du béton. L'utilisation de tels outils de prédiction peut permettre d'économiser des lots d'essai coûteux et chronophages et les travaux expérimentaux associés nécessaires pour obtenir la résistance souhaitée du béton [106]. Les approches d'apprentissage automatique peuvent généralement être classées en deux types principaux: l'apprentissage supervisé et l'apprentissage non supervisé [107] . Le premier a été plus couramment adopté pour estimer les propriétés mécaniques du béton. Dans l'apprentissage supervisé, les modèles ML consistent en des algorithmes informatiques capables de générer des modèles et des hypothèses à travers un ensemble de données fourni pour prévoir les valeurs futures [107–111].

II.5.2 Application de l'intelligence artificiel dans la formulation des Bétons

II.5.2.1 Application des RNA

Le problème de formulation du béton est un problème complexe, il dépend de plusieurs paramètres reliés aux matériaux de composition du béton. Afin de résoudre le problème de formulation du béton, les chercheurs ont été intéressés par l'utilisation des RNA afin de résoudre ces problèmes. Dans ce contexte plusieurs travaux basés sur les RNA ont été réalisés pour étudier les différents paramètres en relation de la formulation du béton. Topcu et Saridemir [112] ont utilisé l'approche RNA pour prédire la résistance à la compression et la résistance à la traction fractionnée du béton d'agrégats recyclés avec de la fumée de silice. Duan et coll. [113] ont utilisé le RNA pour prédire la résistance à la compression du béton contenant des agrégats recyclés provenant de différentes sources. Dantas et coll. [114] ont utilisé le modèle RNA pour prédire la résistance à la compression du béton contenant des déchets de construction et de démolition. Sipos et coll. [115] ont prédit la résistance à la compression du béton de granulats de briques recyclées par RNA et le modèle a ensuite été vérifié par analyse paramétrique. Hendi et coll. [116] ont utilisé RNA pour étudier la durabilité du béton sous attaque acide et a prédit les valeurs de perte de masse pour divers mélanges de béton afin de tirer des conclusions appropriées pour l'utilisation de matériaux supplémentaires. Singh et coll. [117] ont développé un modèle de prédiction de la résistance à la compression en utilisant RNA pour étudier l'influence de la poudre de marbre comme matériau cimentaire. Hadi et coll. [118] ont développé un modèle RNA pour prédire la résistance à la compression du mortier géopolymère à base de cendres volantes. Ils ont incorporé diverses caractéristiques des cendres volantes et des agents activateurs alcalins pour assurer des performances élevées du modèle de prédiction. Chithra et coll. [119] construit un modèle RNA pour prédire la résistance à la compression du béton haute performance contenant de la nanosilice et des agrégats de laitier de cuivre. Le modèle développé utilisait des constituants de mélange comme paramètres d'entrée pour prédire la résistance à la compression. Sojobi et coll. [120] ont développé un modèle RNA pour la prédiction de la résistance à la compression et de la résistance au dérapage de divers blocs de pavés à emboîtement verts à base de médias de cure. Ils ont recommandé une évaluation multicritère des modèles RNA pour une meilleure interprétation de l'efficacité des modèles. Naddaf et Kazemi [121] ont prédit la résistance à la compression des mélanges de mortier constituant différentes classes de ciment. Ils ont développé des modèles RNA sur deux conditions avec et sans la prise en compte de la résistance du ciment pour obtenir un état optimal. Erdem [122] a mis en œuvre RNA pour estimer la capacité de moment des poutres en

béton armé exposées au feu. La capacité de moment prédite par RNA s'est avérée cohérente avec les résultats obtenus par équation empirique. Mashhadban et coll. [123] ont généré un modèle polynomial en utilisant RNA pour prédire les propriétés mécaniques du béton auto-compactant renforcé de fibres. Ils ont rapporté que le modèle RNA formé a réussi à prédire les résultats souhaités des propriétés du béton. Naderpour et coll. [124] ont utilisé RNA pour prédire la résistance à la compression du béton d'agrégats recyclés. Le modèle RNA développé était basé sur six paramètres d'entrée différents et a montré une prédiction efficace de la résistance à la compression. Zhou et coll. [125] prédit la résistance à la compression des prismes de maçonnerie en béton creux par les RNA. Les résultats prédits par les RNA ont été comparés à ceux des approches empiriques et ont montré que le RNA a une excellente capacité de prédiction avec des taux d'erreur négligeables. Dogan et coll. [126] ont prédit la résistance à la compression du béton en utilisant le RNA et le traitement d'image. Ils ont rapporté que la combinaison de RNA et du traitement d'image est une alternative efficace pour prédire les propriétés mécaniques du béton. Momeni et coll. [127] ont développé un modèle RNA prédictif amélioré avec un algorithme génétique pour prédire la capacité portante des pieux. Ils ont rapporté que les résultats prédits par les modèles RNA concordaient fortement avec ceux de la capacité portante mesurée. Armaghani et coll. [128] ont mis en évidence des modèles RNA simples et hybrides intelligents pour prédire le taux de pénétration des tunneliers. Ils ont conclu que l'utilisation de modèles intelligents hybrides RNA avec des RNA simples donnait de meilleurs résultats comparables.

D'autres recherches basées sur les NN dans le domaine de la technologie du béton ont été initialement développées. Ces applications concernaient principalement le dosage des mélanges [60], l'hydratation [11], l'ouvrabilité [7], la résistance à la compression [129], [130] et la durabilité du béton [129], [131], [132]. Pour FL, les premières applications ont été conduites par l'industrie du ciment pour contrôler intelligemment les usines de broyage de ciment [133]. Quelques applications visent à prédire la résistance à la compression des ciments et bétons contenant des cendres volantes [134], [135]

II.5.2.2 Application du système hybride RNA-PSO

Peu de modèle RNA-PSO ont été développées pour l'optimisation et la prédiction des paramètres du béton, une étude proposée par In-Ji Han et al. [136] a montré l'efficacité du système hybride RNA(BP)-PSO pour la prédiction de la résistance à la compression (CS) du béton de laitier de haut fourneau granulé broyé (GGBFS).

Dans cette étude l'architecture optimisée de le RNA proposé est composé d'une seule couche cachée avec 15 neurones, un seul neurone dans la couche de sortie a été proposé et qu'il représente le (CS), 7 neurones dans la couche d'entrée ont été apportés et quelles représentent : les la température de durcissement (T), le rapport eau / liant (E / L), le rapport GGBFS au liant total (GGBFS / B), l'eau (W), l'agrégat fin (FA), l'agrégat grossier (CA) et superplastifiant (SP). Dans ce travail, l'algorithme PSO a été utilisé pour déterminer les points initiaux optimaux quasi globaux au lieu des poids initiaux aléatoires pour la formation BP du RNA.

II.6 Conclusion

Un nombre significatif de systèmes des réseaux de neurones et des algorithmes d'essaim de particule (PSO) ont été développés récemment pour la prévision des propriétés des bétons et en particulier l'ouvrabilité et la résistance à la compression car ces dernières représentent les propriétés principales d'un mélange de béton.

Les résultats de ces modèles prouvent que l'approche RNA est considérée en tant qu'outil utile et puissant en résolvant une classe importante de problèmes de prévision des propriétés des bétons en comparant aux méthodes statistiques et aux approches conventionnelles.

Cependant, l'application de cette approche pour la formulation des bétons compacté au rouleau (BCR) est très onéreuse à cause de la complexité du problème de formulation. C'est pourquoi on s'intéresse dans cette étude à la formulation des BCR aux ajouts (fillers calcaires) en utilisant la structure hybride RNA-PSO, qui est plus performante que les RNA. La base de données, la méthodologie, le développement et l'implémentation de ces modèles seront discutés dans les chapitres suivants.

CHAPITRE III

*Modélisation et prédiction intelligente
de la compacité des mélanges
granulaires, applicables aux bétons
compactés au rouleau (BCR)*

III.1 Introduction

Les bétons compactés aux rouleaux « BCR » utilisés pour les barrages sont des bétons faiblement dosés en ciment ($<200 \text{ kg/m}^3$) et sont conçus par un squelette granulaire assez complexe et particulier, contenant des fillers et différents sables et graviers, de diamètre maximal pouvant aller jusqu'à 80 mm. De ce fait, les méthodes de formulation des BCR sont un peu différentes à celle des bétons conventionnels et se bases beaucoup plus sur les essais expérimentaux d'optimisation des différents paramètres essentiels, en particulier la compacité du mélange granulaire qui conditionne par la suite le choix et le volume de la pâte de liant (ciment, additions, eau et adjuvants).

La conception d'un mélange granulaire avec une compacité souhaitée, implique l'utilisation d'un ensemble de composés granulaires de caractéristiques géométriques et physiques variables. Les proportions des différents composants sont optimisées généralement moyennant une étude paramétrique méthodique s'appuyant sur la mesure ou la prédiction de la compacité du mélange granulaire globale. Plusieurs méthodes expérimentales existent pour la mesure de la compacité [3,137,138]. Ces méthodes utilisent néanmoins des procédures différentes et ne sont toujours applicables à tous les mélanges granulaires. D'autres approches théoriques pour la prédiction de la compacité basées sur des modèles mathématique [32,139], empiriques ou d'intelligence artificielles [140] ont été développées. Ces méthodes restent toutefois limitées à des mélanges de béton ordinaire d'une part, et d'autre part, nécessitent la connaissance d'une multitude de paramètres des matériaux utilisés, qui devons être déterminés expérimentalement avec des manipulations délicates et contraignantes. Ceci rend souvent ces procédures lourdes et réduit considérablement l'aspect pratique de leur utilisation.

L'objectif principal de ce chapitre se résume en une contribution à la mise en place d'un modèle métaheuristique pour la prédiction de la compacité des mélanges granulaires aux bétons compactés rouleaux « BCR », en se basant principalement sur des propriétés géométriques basiques des mélanges, mesurées par des essais expérimentaux. Les réseaux de neurones artificiels ainsi que les essais de particules PSO, seront utilisés comme algorithmes d'optimisation intelligente.

III.2 Matériaux et essais

III.2.1 Matériaux utilisés

Dans cette étude, nous avons utilisé des granulats concassés d'origine naturelles (Figure III. 1) à s'avoir :

- **Filler calcaire**

Le filler est appelé aussi fine ou fine d'addition, représente des granulats de dimension compris entre 0 à 80 μm environ, ce type de granulat est destiné généralement à la réalisation des bétons compacté au rouleau (BCR). La provenance des filles utilisées dans notre étude est de la Wilaya de Mostaganem (Algérie).

- **Les sables**

Dans notre étude deux types de sables ont été utilisées : un sable jaune S_1 (0/2) de provenance de la région de BOUGAZOUL (Wilaya de Média, Algérie), et un sable lavé S_2 (0/5) de provenance de Baghlia (Wilaya de Boumerdès).

- **Les graviers**

Dans ce travail, six fractions granulaires de graviers ont été utilisées à s'avoir les graviers : $G_{3/8}$, $G_{8/15}$, $G_{15/25}$, $G_{25/40}$, $G_{25/50}$, $G_{25/63}$ de provenance Hammam El Oune (wilaya de Blida en Algérie).



Figure III. 1 Les granulats utilisés

III.2.1.1 Caractérisation

III.2.1.1.1 Granulométrie

Le but principal de la réalisation d'une analyse granulométrique est de déterminer la répartition des grosseurs et des pourcentages pondéraux ou volumétriques de différents groupes de fraction granulaire. Deux techniques d'analyse ont été utilisées :

- L'essai de granulométrie par tamisage a été utilisé pour les fractions granulaires ayant un diamètre \geq à 63 μm , selon la norme **NF EN 933-2**,
- Pour les fillers de diamètre inférieure à 63 μm , l'essai de granulométrie par sédimentométrie a été utilisée selon la norme **NF P94-057**.

Les courbes granulométriques du filler et des sables S_1 et S_2 sont représentées dans la Figure III. 2. Celle des graviers et ballastes sont représentées dans la Figure III. 3. Les propriétés géométriques tirées des courbes granulométriques des différents matériaux utilisés, sont présentées dans le tableau III.1.

Tableau III. 1 Récapitulatif des propriétés granulométriques des différents fractions granulométriques

	D _{max}	D ₁₀	D ₃₀	D ₅₀	D ₆₀	D ₈₀	Cu	C _c	MF
Fillers	1	0,003	0,007	0,015	0,025	0,082	8,333	0,653	-
Sable S ₁	1,60	0,150	0,180	0,218	0,219	0,254	1,46	0,986	0.87
Sable S ₂	6.30	0,382	0,900	1,590	1,900	2,843	4,974	1,116	3.45
Gravier 3/8	8	2,987	3,894	4,500	4,592	6,349	1,537	1,105	-
Gravier 8/15	16	9,000	12,875	14,500	15,423	15,863	1,714	1,194	-
Gravier 15/25	25	15,956	18,000	19,500	19,897	22,537	1,247	1,020	-
Gravier 25/40	40	28,586	32,267	35,036	36,890	39,543	1,290	0,987	-
Gravier 25/50	50	32,542	32,598	37,956	42,97	48,523	1,320	0,760	-
Gravier 25/63	63	32,671	32,671	38,120	43,28	51,389	1,324	0,755	-




Figure III. 2 Courbes granulométriques du filler et des sables




Figure III. 3 Courbes granulométriques des graviers et ballastes

Cu est le coefficient de Hazen (Coefficient d'uniformité) calculé selon l'équation Eq. III. 1 et Cc est le coefficient de courbure Eq. III. 2 .Mf est le module de finesse calculé par l'Eq. III. 3

$$C_u = \frac{D_{60}}{D_{10}} \quad \text{Eq. III. 1}$$

$$C_c = \frac{D_{30}^2}{D_{10} \times D_{60}} \quad \text{Eq. III. 2}$$

$$MF = \frac{1}{100} \sum \text{des refus cumulé (\%)} \text{des tamis (0,16 ; 0,315 ; 0,63 ; 1,25 ; 2,5 ; 5)} \quad \text{Eq. III. 3}$$

III.2.1.1.2 Masses volumiques

- **Masse volumique absolue (ρ_{abs})**

Elle représente la masse de l'unité d'un volume absolu d'un corps, d'une autre façon, c'est la masse de la matière du corps, sans tenir en compte le volume des vides, elle est calculée selon la norme **NF EN 1097-7**.

- **Masse volumique apparente (ρ_{app})**

Elle représente la masse de l'unité d'un volume apparent d'un corps, c'est-à-dire le volume constitué par la matière d'un corps incluant les vides qu'elle contient, elle est mesurée selon la norme **NF EN 1097-3**.

La Figure III. 4 illustre les essais de mesure des masses volumique absolue et apparente. Les résultats des différentes masses volumiques sont mentionnés dans le tableau III.4



Figure III. 4 Essais de mesure des masses volumiques : (a) absolue ; (b) apparente

Tableau III. 2 Les masses volumiques des différents granulats utilisés

	Fillers	S 0/2	S 0/5	G 3/8	G 8/15	G 15/25	G 25/40	G 25/50	G 25/63
ρ_{abs} (kg/m ³)	2,73	2,60	2,57	2,78	2,72	2,71	2,62	2,60	2,59
ρ_{app} (kg/m ³)	2,60	1,49	1,59	1,35	1,40	1,35	1,31	1,31	1,32

III.2.1.1.3 Propriétés mécaniques

La propriété mécanique des granulats est généralement exprimée par la dureté, qui est exprimée comme étant la résistance d'un échantillon de roche à se briser sous un choc et l'usure par frottement.

- **Essai Los Angeles**

Los Angeles (L_A) représente un essai qui estime la résistance à la fragmentation par chocs et à l'usure par frottement du granulat. Le L_A est mesuré en fonction du rapport de la masse des fragments passant au tamis de 1,6 mm mesuré en fin d'essai par rapport à la masse de l'échantillon, cet essai est effectué au laboratoire sur les granulats utilisés, selon la norme **NF EN 1097-2**.

- **Essai Micro-Deval**

Cet essai a pour but de déterminer la résistance à l'usure par frottements d'un granulat. Cette résistance est caractérisée par le coefficient Micro-Deval (M_{DE}) qui représente la proportion d'éléments fins produits pendant l'essai. Plus la résistance à l'usure des graviers est élevée plus le coefficient M_{DE} est faible. L'essai de Micro-Deval a été effectué, au laboratoire sur les granulats utilisés, selon la norme **NF EN 1097-1**.

La Figure III. 5 illustre le matériel utilisé pour le calcul des deux propriétés mécaniques. Les résultats des essais sont présentés dans le Tableau III. 3




Figure III. 5 Essais mécaniques sur granulat : (a) Los Angeles ; (b) Micro Deval

Tableau III. 3 Résultats des coefficients de LA et MDE

Coefficients	G _{8/15}	G _{15/25}	G _{25/63}
L _A	21,64	21,23	19,86
M _{DE}	23,17	22,84	16,12

III.2.1.1.4 Propreté

La propreté peut être définie par deux indications, la première désigne la teneur en fines argileuses ou autre particules adhérentes à la surface des grains, ce qui se vérifie sur le chantier par les traces qu'elles laissent lorsqu'on frotte les granulats entre les mains. D'autre part, les impuretés susceptibles de nuire à la qualité du béton, parmi lesquelles on peut citer les scories, le charbon, les particules de bois, les feuilles mortes, les fragments de racine.

➤ **Equivalent de sable**

L'essai d'équivalent de sable permet la mesure de la propriété d'un sable, ainsi que celle de la fraction d'un granulat passant au tamis de 5mm. Il rend compte globalement de la quantité des éléments fins, en exprimant un rapport conventionnel volumétrique entre les éléments sableux qui sédimentent et les éléments fins qui flocculent.

La valeur de l'équivalent de sable au piston « Esp » est le rapport, multiplié par 100 de la hauteur de la partie sableuse sédimentée, à la hauteur totale flocculat et de la partie sableuse sédimentée. L'essai est réalisé selon la norme NF P18-598, Le Tableau III. 4 récapitulatif les résultats d'essai des sables étudiés.

Tableau III. 4 Résultat d'équivalent des sables

Equivalent de sable	S _{0/2}	S _{0/5}
E _{Sp} (%)	73,54	76,14

➤ **Propreté superficielle**

La qualité des granulats représente un facteur primordial dans les bétons hydrauliques. En plus de l'exigence d'une bonne répartition granulaire et d'une forme favorable, le granulat doit présenter une propreté acceptable. En effet, si les granulats sont enrobés par une quantité excessive d'éléments fins, généralement argileux, ceux-ci empêchent une bonne adhérence de

la pâte liante, entraînant ainsi une chute des résistances mécaniques et des variations de propriétés rhéologiques du mélange. L'essai a été réalisé selon la norme NF EN 933-8, Le Tableau III. 5 illustre les résultats de propreté des granulats.

Tableau III. 5 Propreté superficielle des graviers

	G _{8/15}	G _{15/25}	G _{25/40}	G _{25/50}	G _{25/63}
ρ_s (%)	2,35	1,36	1,3	1,24	0,98

III.2.2 Compacité des mélanges granulaire

III.2.2.1 Méthodes de mesure de la compacité

Après la présentation de tous les mélanges granulaires choisis, l'étape suivante est de mesurer la compacité de ces mélanges. Comme nous avons mentionné précédemment (chapitre I), plusieurs méthodes d'essais normalisés de la mesure de la compacité sont citées dans la littérature, les deux procédés jugés les plus efficaces pour atteindre une compacité maximale restent un compactage par table à choc ou sous vibration avec un chargement donnée, généralement ne dépassant pas les 10 KPa.

La différence entre les méthodes de mesure de la compacité d'un mélange granulaire donné, en terme d'efficacité, a été expliqué par plusieurs chercheurs [141]. Sadok A. [137] dans son travail a effectué des mesures de compacité sur différents mélanges granulaires par différentes méthodes. Comme le montre la Figure III. 6, il a pu démontrer que les deux méthodes (table à

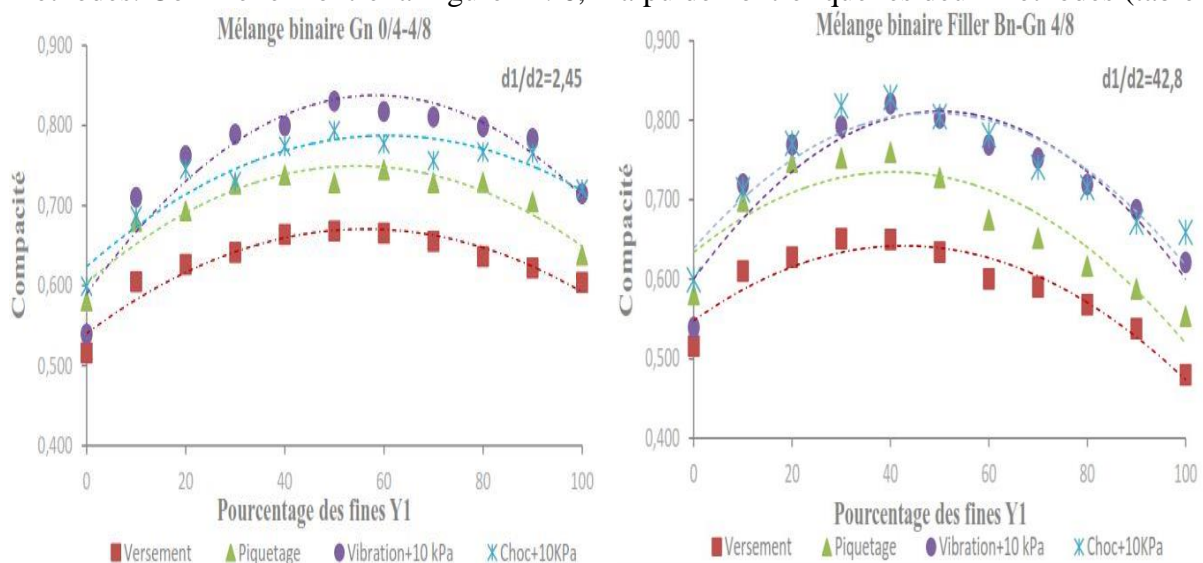


Figure III. 6 Mesure de la compacité granulaire par différentes méthodes [1]

choc et vibration sous chargement) donnent des meilleurs résultats de la compacité par rapport à d'autres méthodes (versement simple ou piquetage).

D'autres travaux [30,142] ont aussi prouvé l'efficacité des deux méthodes de compactage (Par table à choc avec un chargement de 10 KPa et Compactage sous vibration avec pression de 10 KPa) pour des mélanges granulaires ayant des $D_{\max} = 25$ mm.

La compacité granulaire dépend de plusieurs facteurs, les plus importants est l'effet de paroi (Graine/Paroi du moule utilisé dans l'essai), l'interaction entre les grains, ou encore les paramètres du dispositif lui-même tel que les dimensions du moule, le moyen et l'énergie (puissance et temps) de compactage et la charge appliquée [3]. L'objectif principal d'un tel procédé est de définir la compacité maximale d'un mélange granulaire donné. Ceci implique une optimisation des différents paramètres du bon d'essai utilisé (Dimensions du moule, moyen et l'énergie de compactage, charge, ...).

III.2.2.2 Méthode expérimentale utilisée

Notre travail se base principalement sur la détermination expérimentale de la compacité d'une multitude de mélanges granulaires, composés de plusieurs types de granulats (mélanges de 2 à 6 granulats) ayant des caractéristiques géométriques et physiques différentes (D_{\max} de 2 à 63 mm). Ces mélanges, rappelons-le, couvrent les bétons compactés au rouleau (BCR) pour route et pour barrages. Cette diversité nous a conduits à penser au développement d'un procédé expérimental bien adapté à la nature du problème. Dans cette optique, d'une part, nous avons opté pour un dispositif expérimental en se basant sur le compactage par vibration sous un chargement. D'autre part, au regard de la valeur du diamètre maximal des granulats utilisés dans notre étude, qui atteint les 63mm, nous nous sommes orientés et inspirés de la norme NF EN 13286-5 qui prend en considération les granulats ayant un D_{\max} jusqu'à 80 mm. Cette norme propose un procédé de compactage avec une table vibrante d'une fréquence de (50 ± 2) Hz, sous un chargement de capacité comprise entre 80kg et 100kg et dans un moule cylindrique d'une capacité de 14 l (Hauteur = 230 ± 2 mm ; Diamètre = 280 ± 2 mm).

III.2.2.2.1 Présentation du dispositif expérimental

Le dispositif est composé d'une table vibrante d'une fréquence de 50Hz, un moule cylindrique de diamètre 265mm et hauteur de 254mm utilisé pour la mise en place des mélanges granulaires. La charge de compactage utilisée est assurée par un jeu de disques ayant des masses différentes,

la Figure III. 7 et la Figure III. 8 illustrent respectivement le schéma du dispositif utilisé et les photos réelles du banc d'essai.




Figure III. 7 Schéma représentatif du dispositif utilisé pour la mesure de la compacité




Figure III. 8 Banc d'essai utilisé pour la mesure de la compacité

III.2.2.2 Procédure d'essai

La mesure de la compacité est effectuée selon les étapes suivantes (Figure III. 9) :

- Pesage des différentes fractions granulaires du mélange
- Mise en place des éléments pesés dans un sac d'homogénéisation,
- Remplir le moule cylindrique avec le mélange avec une faible hauteur de remplissage.
- Araser la surface du moule après le remplissage avec une règle,
- Peser l'échantillon avant l'essai et noter la masse « m_1 ».
- Fixer le moule sur la table vibrante et lancer l'essai,
- Mise en place de la charge de compactage,
- Après le temps de vibration, mesurer la hauteur du vide "h" dans le moule à l'aide d'un pied à coulisse numérique (Figure III. 10),
- Mesurer la masse du moule rempli après l'essai " m_2 "




Figure III. 9 Etapes de mesure de la compacité : (a) Remplissage du moule, (b) Arasage de la surface du moule, (c) Compactage, (d) Mesure la hauteur h




Figure III. 10 Mesure de la hauteur (h)

Ainsi, le calcul de la compacité C peut être effectué par l'Eq. III. 4 et l'

Eq. III. 5

$$C = \frac{V_s}{V_T}$$

Eq. III. 4

Avec :

V_s : Volume des solides : $V_s = V_S = S \times (H - h)$ et

V_T : Volume total : $V_T = S \times H$

- H et h représentent la hauteur avant et après le compactage respectivement.

La deuxième méthode :

$$C = \frac{\rho_{app}}{\rho_{réel}}$$

Eq. III. 5

Avec :

ρ_{app} : masse volumique apparente avant compactage

$$\rho_{app} = \frac{m_1}{(S \times H)}$$

Eq. III. 6

$\rho_{réel}$: masse volumique apparente après compactage

$$\rho_{réel} = \frac{m_2}{(S \times (H - h))}$$

Eq. III. 7

III.2.2.2.3 Optimisation des paramètres d'essai

Après avoir mis en place le dispositif d'essai (type de procédé, dimension du moule et fréquence de vibration), il est primordial de fixer les différents paramètres du banc d'essai pour atteindre une compacité maximale, à savoir la valeur de la masse de compactage et le temps de vibration. Pour ce faire, nous avons mis en place un petit programme de tests préliminaires sur quelques mélanges représentatifs, faisant varier ces deux paramètres, l'objectif étant d'optimiser au mieux la procédure d'essai. Dans cette étape, on a fixé 09 mélanges granulaires de (BCR) de compositions différentes (Tableau III. 6). Ainsi, la fréquence de vibration étant fixe, les deux paramètres essentiels étudiés de l'essai sont :

- La charge de compactage exercée sur mélange : 6, 8, 10, 12 et 14 KPa.
- Le temps de compactage : 15, 30, 45 et 60s.

Tableau III. 6 Mélanges utilisés pour les essais préliminaires

N°	Type	Code
1	BCR_D15	BCR_D15_1
2		BCR_D15_1
3		BCR_D15_1
4	BCR_D25	BCR_D25_1
5		BCR_D25_1
6		BCR_D25_1
7	BCR_D40	BCR_D40_1
8		BCR_D40_1
9		BCR_D40_1

Il est à noter que cette étape demeure d'une grande importance pour la suite des essais, qui permettra de fixer la charge et le temps de compactage. Au début, le temps de vibration égale a été supposé égal à 45s pour toutes les mesures effectuées. Les résultats de la compacité des mélanges étudiés en fonction de la variation de la charge de compactage, sont regroupés dans le Tableau III. 7 et représentés dans la Figure III. 11

Tableau III. 7 Variation de la compacité en fonction de la charge de compactage

N°	Type	Mélange	Compacité				
			6 KPa	8 Kpa	10Kpa	12Kpa	14Kpa
1	BCR_D15	BCR_D15_1	0,859	0,855	0,850	0,847	-
2		BCR_D15_1	0,853	0,850	0,849	0,844	-
3		BCR_D15_1	0,864	0,862	0,860	0,861	-
1	BCR_D25	BCR_D25_1	0,889	0,882	0,871	0,865	0,864
2		BCR_D25_2	0,890	0,879	0,867	0,853	0,852
3		BCR_D25_3	0,900	0,897	0,895	0,891	0,891
4	BCR_D40	BCR_D40_1	0,864	0,867	0,866	0,870	0,870
5		BCR_D40_2	0,849	0,842	0,834	0,819	0,819
6		BCR_D40_3	0,857	0,848	0,843	0,828	0,826

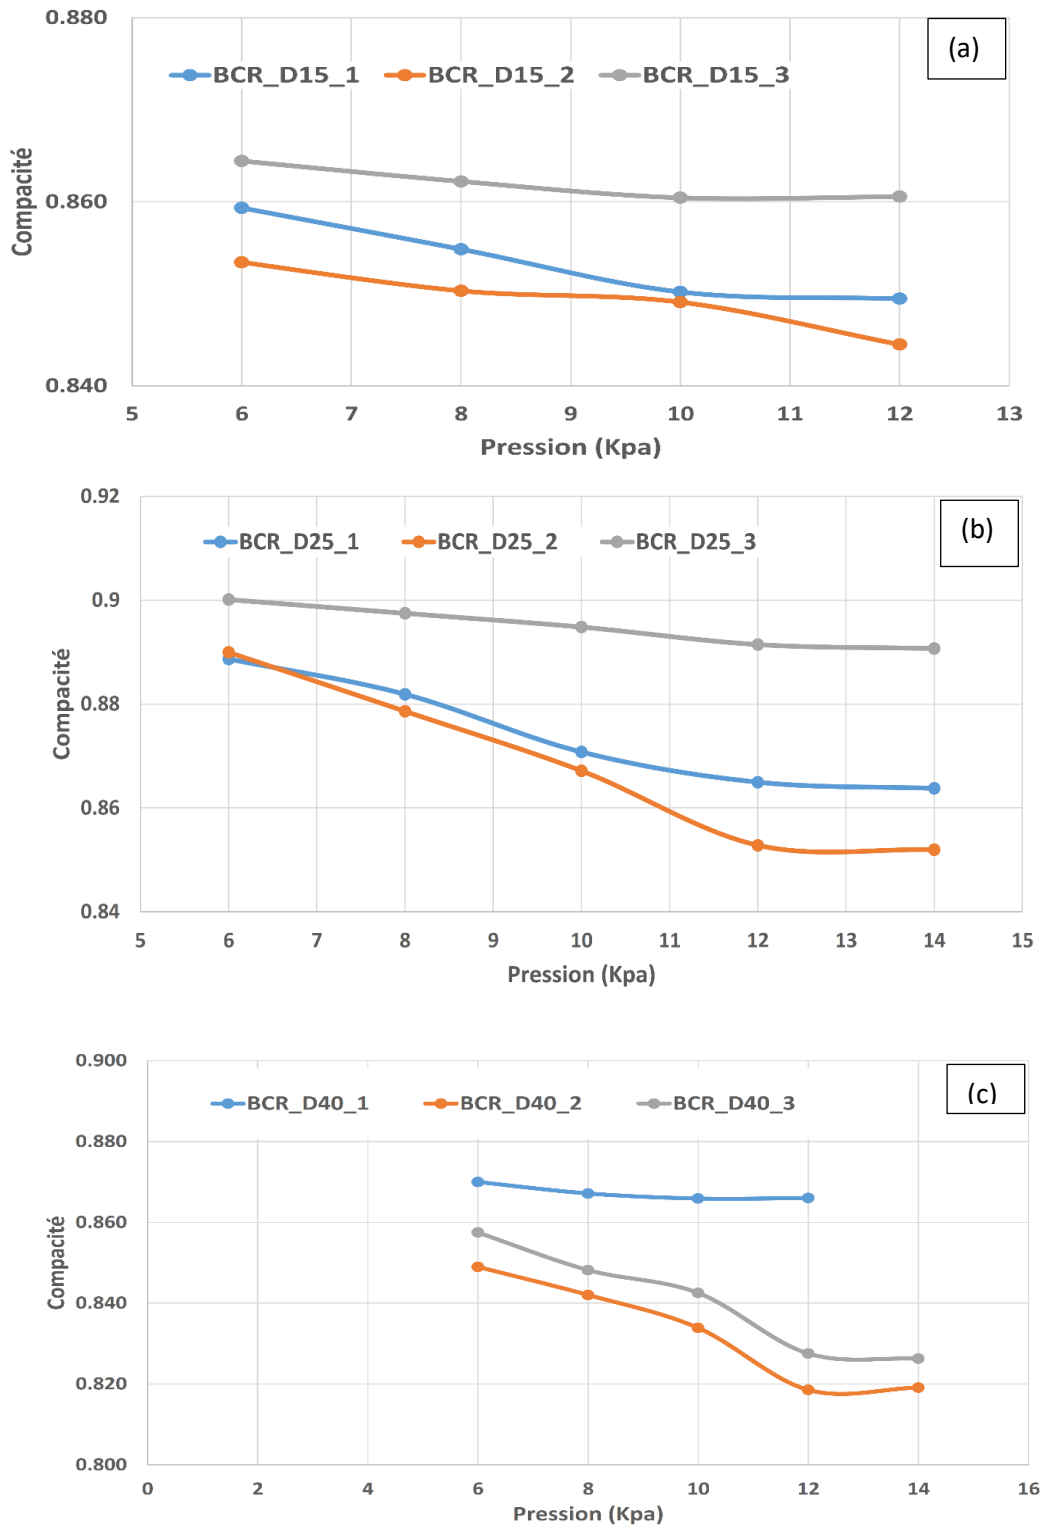


Figure III. 11 Variation de la compacité en fonction de la charge de compactage pour : (a) Dmax = 15mm ; (b) Dmax = 25mm ; (c) Dmax = 40mm

D'après la Figure III. 11 on peut observer que la compacité des mélanges granulaires de BCR étudiés diminue en premier temps avec l'augmentation de chargement, Ce qui est d'ailleurs logiques. A partir d'un chargement de 12 KPa exercé, on remarque que la compacité des mélanges granulaires reste constante.

Après l'optimisation de la charge, nous avons étudié la variation de la compacité en fonction de la variation du temps de vibration, le temps de vibration a été varié de 15s à 60s avec un pas de 15s. Les résultats obtenus sont représentés dans la Figure III. 12




Figure III. 12 Compacité des BCR en fonction de temps de vibration

La figure III. 12 montre une légère variation de la compacité entre 0s à 45s de vibration et après 45s de vibration, la compacité reste constante.

A partir des résultats de cette étude paramétrique, il est évident qu'un temps vibration de 60 s et une charge de compaction de 12 KPa sont des paramètres optimums pour assurer une compacité maximale. De ce fait ces paramètres ont été considérés pour le reste de l'étude.

III.2.2.2.4 Compacités des mélanges d'étude

Après optimisation du banc d'essai, nous avons mesuré la compacité de tous les mélanges de l'étude (174 mélanges). Les mélanges sont stockés et codifiés individuellement après l'essai dans des sacs (Figure III. 13) pour être utilisés ultérieurement pour une autre étude (la masse

des échantillons varis entre 21Kg à 25Kg selon le mélange testé). Les quantités des granulats utilisés dans cette étude sont mentionnées dans le Tableau III. 8.



Figure III. 13 Stockage des mélanges après l'essai

Tableau III. 8 Quantité des granulats utilisés

Granulats	Filler	Sable S ₁	Sable S ₂	Gravier 3/8	Gravier 8/15	Gravier 15/25	Gravier 25/63
Masse (Kg)	160,460	541,374	992,577	660,150	941,080	423,090	412,4

III.3 Modélisation et prédiction intelligente de la compacité des mélanges

III.3.1 Modélisation de la courbe granulométrique

Cette étape de notre travail vise à modéliser la courbe granulométrique du mélange par un ensemble de paramètres géométriques représentant au mieux sa variation. Les paramètres géométriques retenus sont le diamètre maximal D_{max} et les diamètres intermédiaires (D_{10} , D_{30} , D_{50} , D_{60} et D_{80}) (Figure III. 14). A ces paramètres, on ajoute les deux coefficients, courbure C_u et de Hazen C_c , ainsi que le pourcentage des fillers calcaires (Limestone %) utilisé. Ces

paramètres principalement géométriques, seront utilisés comme entrées dans le modèle de prédiction de la compacité développée dans cette partie d'étude.




Figure III. 14 Modélisation d'une courbe granulométrique d'un mélange

III.3.2 Constitution de la base de données

III.3.2.1 Choix des mélanges granulaires

Deux fuseaux granulométriques sont spécifiés avec précision pour couvrir une large gamme de mélanges granulaires de (BCR). Le premier fuseau (Figure III. 15) couvre les mélanges granulaires ayant un diamètre maximal 15mm et 25mm utilisées généralement pour les BCR de routes. Le second fuseau (Figure III. 16), défini pour les BCR de barrages, couvre les mélanges granulaires ayant un diamètre maximal de 40mm, 50mm et 63mm. Les deux fuseaux étudiés ont été définis d'une part sur la base de différents fuseaux granulométriques de référence utilisées usuellement dans les projets de construction des routes et barrages en BCR [143] et d'autre part, en adaptant les courbe de Fuller-Thompson [144] des mélanges granulaires à compacité optimale. Il est toutefois à noter qu'un élargissement des fuseaux de référence d'environ 20 % a été procédé afin d'inclure une plus large gamme de mélanges granulaires.

Au total, 5 types de mélanges sont pris en considération et classés en deux catégories : La première représente les BCR pour application routière, et inclus deux types de mélanges avec des diamètres maximaux D_{max} de 15 mm et 25 mm. La seconde classe évoque trois types de mélanges granulaires de BCR pour barrage avec des diamètres maximaux de granulats de 40mm, 50mm et 63mm. Le tableau III. 9 regroupe les différents matériaux utilisés dans chaque

type de mélange ainsi que le nombre total de mélanges composés par type. Au total, 174 mélanges ont été réalisés et leurs courbes granulométriques sont tracées et modélisées (Paramètres géométriques tirés), les figure III. 17 et Figure III. 18 illustrent les différentes courbes granulométriques des 174 mélanges considérés. Ces courbes ont rempli en totalité la surface des fuseaux granulométriques étudiés.

Tableau III. 9 Compositions des différents mélanges granulaires de (BCR)

Catégorie de (BCR)	Fillers calcaire « F »	S1 0/2	S2 0/5	G1 3/8	G2 8/15	G3 15/25	B1 25/40	B2 25/50	B3 25/63	Nombre total des mélanges
Route	X	X	X	X	X					30
	X	X	X	X	X	X				30
Barrage	X	X	X	X	X	X	X			38
	X	X	X	X	X	X	X	X		43
	X	X	X	X	X	X	X	X	X	33

III.3.2.2 Mesure de la compacité des mélanges

Tous les mélanges granulaires ont été modélisés d'une part, ainsi les paramètres (D_{max} , D_{10} , D_{30} , D_{50} , D_{60} et D_{80} , Limestone%, Cc et Cu) pour chaque mélange ont été tirés. D'autre part, la compacité de chaque mélange a été mesurée expérimentalement au laboratoire par le biais du dispositif d'essai développé et optimisé antérieurement. A partir de ces résultats, une base de données a été constituée avec succès contenant 174 vecteurs d'entrée et de même pour les valeurs de la compacité correspondantes. Un exemple étalé de la base de données sera présenté en annexe. Par ailleurs, et pour donner un bon aperçu des résultats, le Tableau III. 10 présente quelques exemples de mélanges ainsi que les intervalles de variation et l'écart type des différents paramètres d'entrée de de sortie. Ces intervalles montrent une large variation des différents paramètres avec un écart type réduit, témoignant de la richesse de la base de données construite.




Figure III. 15 Fuseau granulaire pour mélanges BCR applicables aux routes




Figure III. 16 Fuseau granulaire pour mélanges BCR applicables aux barrages




Figure III. 17 Mélanges granulaires étudiés avec des diamètres maximaux Dmax 15 mm et 25mm




Figure III. 18 Mélanges granulaires étudiés avec des diamètres maximaux Dmax de 40, 50 et 63 mm

Tableau III. 10 Exemples et intervalles de variation des paramètres des mélanges granulaires

Parameters	Limestone filler (%)	D _{max}	D ₁₀	D ₃₀	D ₅₀	D ₆₀	D ₈₀	C _u	C _C	Compacité
1	3	15	0,180	1,875	5,337	7,488	11,087	41,6	2,608	0,836
2	7	25	0,148	0,552	3,774	4,767	8,000	32,209	0,432	0,830
3	11	40	0,094	0,486	3,035	5,123	16,943	54,5	0,490	0,854
4	15	50	0,035	0,458	4,299	5,514	11,773	154,218	1,063	0,841
5	13	63	0,066	3,045	6,588	13,304	32,424	201,575	10,600	0,867
Min	2	15	0,015	0,219	2,059	3,465	6,256	27,025	0,109	0,798
Max	20	63	0,243	7,158	17,108	21,317	35,396	743,611	63,50	0,864
Ecart type	-	-	0,068	1,648	3,263	4,152	6,409	118,06	8,803	0,014

III.3.3 Description et développement des modèles intelligents de prédiction de la compacité

III.3.3.1 Modèle de Réseau de Neurones Artificiel « RNA »

Pour le développement du modèle de prédiction de la compacité, la métaheuristique Réseau de Neurones Artificiel « RNA » a été choisie. Pour ce faire, un RNA de type perceptron multicouche à rétropropagation (BPMLP), le plus utilisé dans le domaine, a été considéré. La base de données (174 vecteurs) a été divisée en trois parties : 70% a été utilisée pour l'apprentissage, 15% pour le test et 15% pour la validation.

Les constituants du vecteur d'entrée d'un RNA présentent différentes extrémités quantitatives, de ce fait, une normalisation des données est nécessaire. Dans cette optique, les valeurs de la base de données ont été normalisées dans l'intervalle [-1, +1] avant le processus d'apprentissage. Cette procédure de normalisation assure une cohérence avec les limites de la fonction sigmoïde tangente utilisée dans les neurone de la couches cachées et de la sortie [55]. Plusieurs formules ont été proposées dans le but de normaliser le vecteur d'entrée d'un RNA, l'équation Eq. III. 8, choisie dans notre étude, est considérée parmi les plus utilisés [79].

$$x_n = \frac{(y_{max} - y_{min}) \times (X - X_{min})}{(X_{max} - X_{min})} + y_{min} \quad \text{Eq. III. 8}$$

Où :

x_n : La valeur normalisée

y_{max} et y_{min} : Les valeurs maximum et minimum de normalisation égales à +1 et -1 respectivement.

X : Vecteur d'entrée des données avant la normalisation

X_{max} , X_{min} : Valeurs maximum et minimum du vecteur d'entrée X

Après la création du RNA, les valeurs de vecteur de sortie obtenu par le RNA doivent être retransformées en valeurs réelles à l'aide de l' Eq. III. 9. Le processus s'appelle alors dé-normalisation des données.

$$y = \frac{(y_n - y_{min}) \times (X_{tmax} - X_{tmin})}{(y_{tmax} - y_{tmin})} + X_{tmin} \quad \text{Eq. III. 9}$$

Où :

y et y_n : Valeur de sortie réelle et la valeur de sortie normalisée respectivement,

y_{max} et y_{min} : Valeurs maximum et minimum de vecteur de sortie Y ,

X : Vecteur d'entrée des données avant la normalisation,

X_{tmax} et X_{tmin} : Valeurs maximum et minimum de vecteur d'entrée X ,

III.3.3.1.1 Architecture du RNA

Le RNA a été construit selon l'architecture suivante :

- Une couche d'entrée
- Une cachée,
- Une couche de sortie.

Sur la base des paramètres issus de la modélisation de la courbe granulométriques du mélange (Limestone (%), D_{max} , C_u , C_c , d_{10} , d_{30} , d_{50} , d_{60} , d_{80}), neuf (09) neurones ont été retenues dans la couche d'entrée. Le neurone de la couche de sortie représente la compacité du mélange granulaire. Pour développer un modèle RNA avec une performance optimale, une série de simulations avec variation du nombre de neurones de la couche cachée a été réalisée. Pour cela l'algorithme d'apprentissage Levenberg-Marquardt « LM » a été utilisé. Les meilleurs résultats ont été obtenus pour un RNA ayant : 9 neurones dans la couche d'entrée, 11 neurones dans la couche cachée et 1 neurone dans la couche de sortie (Figure III. 19). Cette architecture du réseau RNA est utilisée pour le reste de l'étude.




Figure III. 19 Modèle PSO-RNA pour la prédiction

III.3.3.2 Modèle hybride RNA-PSO

Afin d'améliorer les performances du modèle RNA développé avec l'algorithme LM, une hybridation est proposée. Il s'agit d'optimiser les paramètres de l'RNA (Poids et biais) par un algorithme PSO dans l'étape d'apprentissage. La Figure III. 20 illustre le fonctionnement du modèle hybride développé. Au début, les paramètres poids et biais de l'RNA sont considérés comme des particules de l'essaim PSO. Par la suite, les particules sont générées de façon aléatoire, chaque particule de l'essaim ayant une position X_i et une vitesse de recherche V_i . Après chaque nouvelle itération les positions ainsi que les vitesses de chaque particule sont corrigées afin de se rapprocher vers l'optimum. Enfin, les valeurs finales des paramètres de l'RNA sont obtenues après les corrections successives des paramètres P_{best} et G_{best} générés par l'actualisation des équations II.12 et II.13

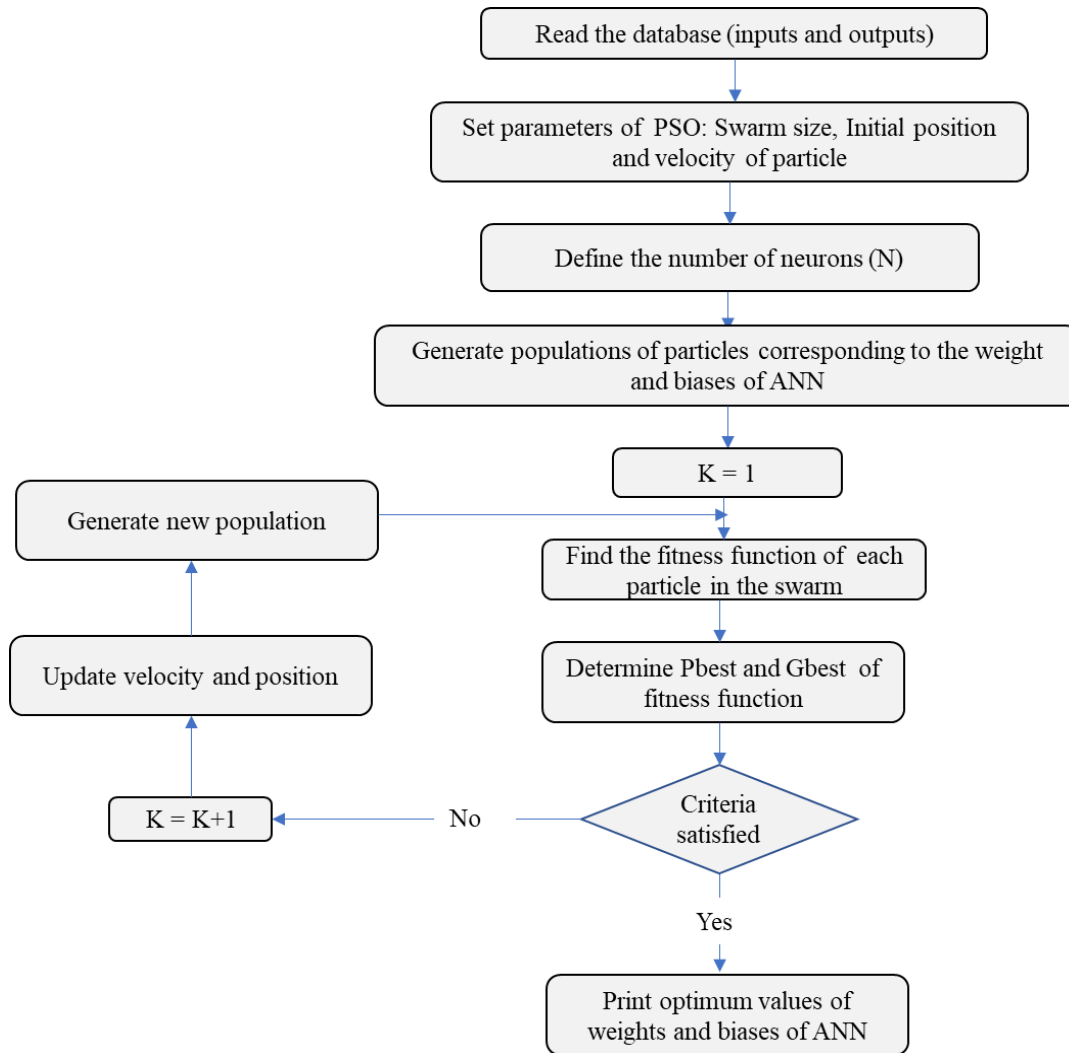


Figure III. 20 Organigramme du modèle PSO-RNA

Les différents paramètres du modèle RNA-PSO proposé pour la prédiction de la compacité sont regroupés dans le Tableau III. 11. L'algorithme PSO présente généralement ses meilleures performances avec des coefficients d'accélération C_1 et C_2 compris, respectivement, de 1 à 2,5 et de 2 à 3 [145]. Après une variation successive de ces coefficients dans les plages recommandées, les meilleurs résultats ont été obtenus pour $C_1=1,5$ et $C_2=2,5$. La Figure III. 21 présente la variation de l'erreur quadratique « RMSE » en fonction du nombre des itérations. Un agrandissement des vingt premières et vingt dernières itérations a été fait pour mettre en évidence l'influence de la taille de population du PSO la performance du modèle. La meilleure performance a été obtenue pour une population de 500.

Tableau III. 11 Paramètres du modèle PSO-RNA développé

RNA			PSO			
Couche d'entrée	Couche cachée	Couche de sortie	Itération	C ₁	C ₂	Population
9	11	1	2000	1,5	2,5	500




Figure III. 21 Variation de l'erreur quadratique en fonction du nombre d'itérations.

III.3.4 Performance et validation des modèles RNA et RNA-PSO

Les résultats de prédiction de la compacité des modèles RNA et RNA-PSO sont respectivement présentés par la Figure III. 22 et la Figure III. 23, qui montrent la régression linéaire entre les compacités expérimentales et celle prédites. Les figures présentent d'une part la régression de l'ensemble des données et, d'autre part, la régression de validation assurée par les 15 % de données, n'ayant pas été utilisées dans l'étape d'apprentissage.

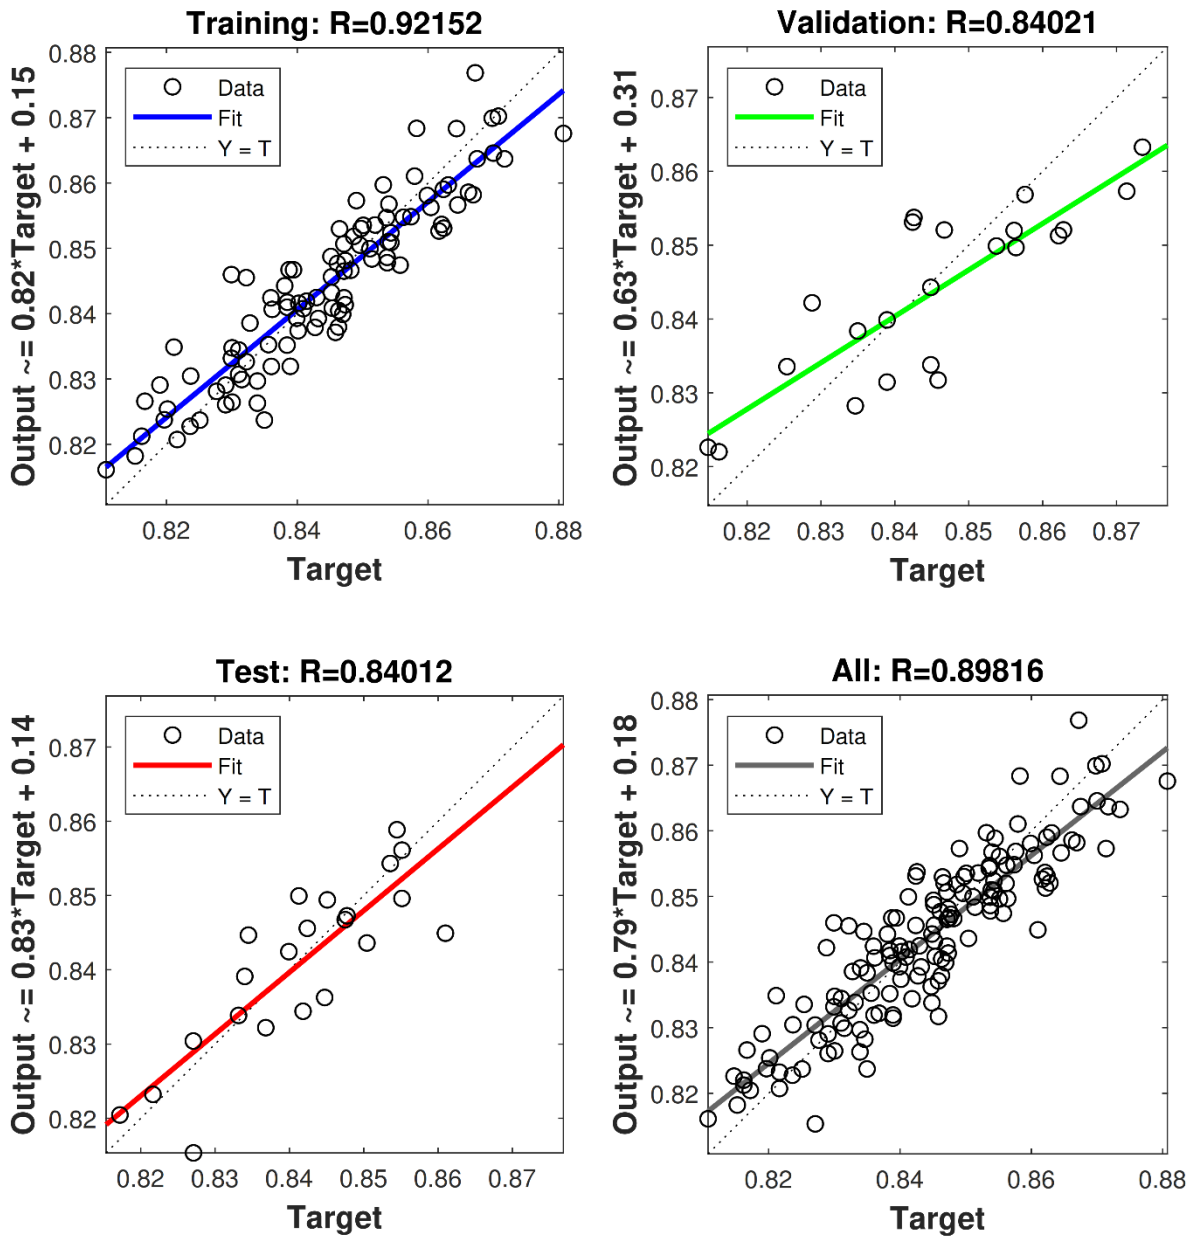


Figure III. 22 Résultats de régression obtenus par le modèle RNA : (a) Entraînement ; (b) Validation data ; (c) teste ; (d) totale

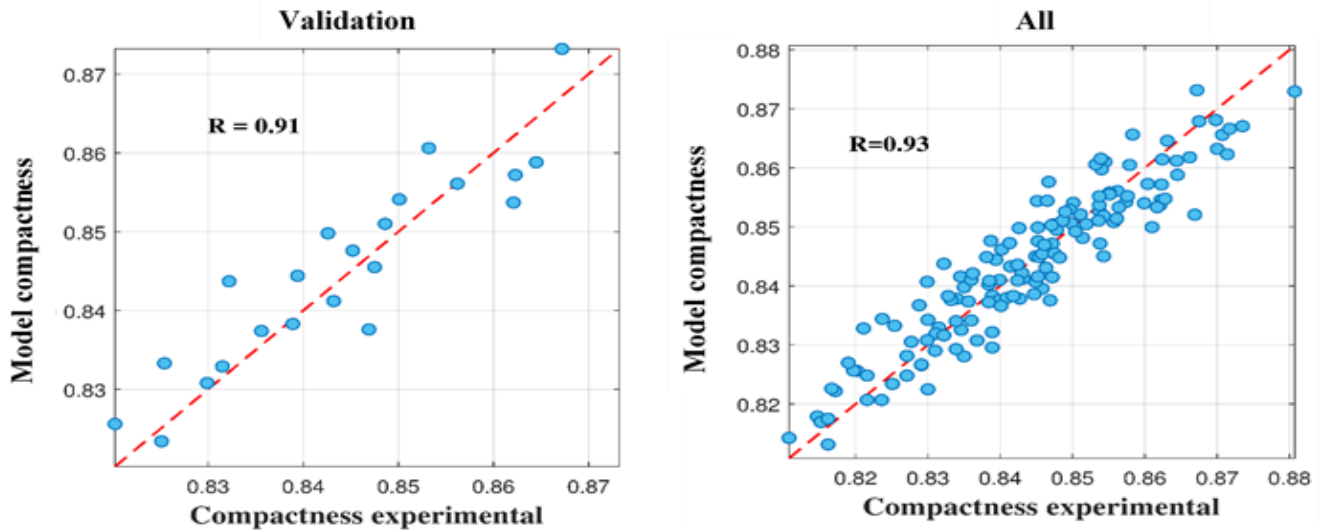


Figure III. 23 Résultats de régression obtenus par le modèle PSO-RNA : (a) Validation ; (b) totale.

La performance des deux modèles développés a été évaluée par plusieurs indicateurs statistiques : MSE (Mean Square Error) Eq. III. 10, RMSE (Root Mean Squared Error) Eq. III. 11, MAE (Mean Absolute Error) Eq. III. 12, MAPE (Mean Absolute Percentag Error) Eq. III. 13 et le coefficient de corrélation R (Eq. III. 14).

$$MSE = \frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2 \quad \text{Eq. III. 10}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad \text{Eq. III. 11}$$

$$MAE = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad \text{Eq. III. 12}$$

$$MAPE = \frac{1}{n} \sum_{j=1}^n \left(\left| \frac{\hat{y}_j - y_j}{\hat{y}_j} \right| \mathbf{100} \right) \quad \text{Eq. III. 13}$$

$$R = \sqrt{\mathbf{1} - \left(\frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2} \right)} \quad \text{Eq. III. 14}$$

Avec **n** nombre de points, y_j et \hat{y}_j représentes respectivement les valeurs expérimentales et celles prédites par le modèle et \bar{y} est la valeur moyenne des mesures expérimentales.

Les résultats de performances, selon les indicateurs statistiques, des deux modèles développés RNA et RNA-PSO sont présentés dans le Tableau III. 12. Au regard de ces résultats, il apparaît clairement que le modèle hybride RNA-PSO présente de meilleurs résultats que ceux du modèle RNA. En effet, en comparaison avec le modèle RNA, le modèle RNA-PSO affiche une diminution d'environ 34 % de la MSE, de 11% de la MAE et de 12 % de la MAPE. De même une amélioration de 4 % du coefficient de corrélation R a été observée pour la régression du modèle RNA-PSO. A partir de là, on peut avancer l'efficacité de l'algorithme PSO dans l'optimisation des paramètres du RNA (poids et biais) par rapport à une optimisation classique par l'algorithme de Levenberg-Marquardt LM.

Tableau III. 12 Performance du RNA et PSO-RNA modèle

Model	MSE	RMSE	MAE	MAPE (%)	R
RNA-PSO	2,718E-05	0,0052	0,0042	0,5030	0,9328
RNA	4,1312E-05	0,0064	0,0047	0,5683	0,8981

III.3.5 Analyse paramétrique de sensibilité

La compacité « C » d'un mélange granulaire est un paramètre complexe dépendant d'une diversité de paramètres, principalement la taille et proportions des grains, la forme des grains, le mode de compactage [5, 16], les proportions des granulats fines par rapport aux gros grains [44], ainsi que le type et des dimensions du moule utilisé (effet de paroi) [15]. Pour analyser le comportement du modèle développé, une étude de sensibilité a été conduite, montrant la variation de la compacité du mélange granulaire mesurée et prédite en fonction de deux paramètres de première influence [5, 14], soit le taux de fines et le diamètre maximal D_{max} . Dans cette étude, le taux de fine est défini par le pourcentage des granulats ayant un diamètre maximum $\leq 5\text{mm}$, dans notre cas le taux de fines représente les fillers calcaires de (0/1mm) ainsi que les sables (0/2mm) et (0/5mm).

Etant donné la complexité du problème et la diversité géométrique des fractions granulaires des mélanges, la variation des paramètres d'étude (D_{max} et le taux de fines), ont été variés pour des mélanges granulaires ayant des courbes granulométriques d'une allure assez proche. De même les compacités ont été effectuées selon le même mode de compactage (table vibrante ASTM C1176) afin de minimiser le plus possible la variation et l'influence des autres paramètres.

Les résultats de l'étude de sensibilité de la variation de compacité en fonction du D_{max} et du taux de fine sont présentés dans la Figure III. 24, la Figure III. 25 et la Figure III. 26

En premier lieu, la Figure III. 23 illustre la variation des compacités des mélanges granulaires, mesurés et prédites, en fonction de la variation du taux de fine pour différente D_{max} .

Pour un D_{max} de 15mm (figure III.24-a), la variation de la compacité avec le taux de fines est assez typique. En effet, la compacité augmente jusqu'à un optimum correspondant à environ 45% de fines, puis prend une tendance baissière, Sadok et al. [140] a prouvé dans son travail de prédiction de la compacité que les pourcentages des fines améliorent la compacité jusqu'à une certaine valeur, puis l'amélioration de la compacité diminue avec l'augmentation du taux de fines.

Pour les D_{max} de 25 à 63 mm (Figures III.24 -b, c, d et e), la tendance de la compacité est à la hausse en fonction de l'augmentation du taux de fine, variant de 25 à 60% environ. Par ailleurs, on peut constater que cette augmentation est de plus en plus significative que le D_{max} augmente pour les mélanges granulaires considéré. Dans ces cas, pour les mélanges étudiés, il semble que le taux de fines étudié (jusqu'à 60%) n'a pas encore permis l'obtention d'une compacité maximale, au-delà de laquelle, on peut observer sa diminution.

Le résultat obtenu s'explique que l'amélioration de la compacité est due au remplissage des vides inter-granulaires dans les mélanges jusqu'à saturation totale des vides, après la saturation et avec l'augmentation de pourcentage des fines la compacité diminue. de Larrard [32] a étudié la variation du taux de fines en fonction du diamètre maximale, les résultats obtenu ont prouvées qu'avec l'augmentation de l'étendue granulaire (augmentation du D_{max}) l'amélioration de la compacité sera plus significatif avec l'augmentation de pourcentage des fines jusqu'à une certain valeurs, après et pour une certaine limite, la valeur de la compacité diminue avec l'augmentation des pourcentage des fines jusqu'à une valeur constante pour 100% de fine dans le mélange, ce qui se traduit par la saturation totale des vides. Sedran [146] Dans un travail similaire sur le développement d'un modèle de prédiction de la compacité a constaté les mêmes résultats obtenus par de Larrard sur le principe de l'influence de la variation du taux de fines et du diamètre maximum sur l'amélioration de la compacité du mélange granulaire. Il est à noter que plusieurs autres travaux ont trouvé les mêmes tendances de la variation de la compacité en fonction du D_{max} et du taux de fines [22,138,142,147]

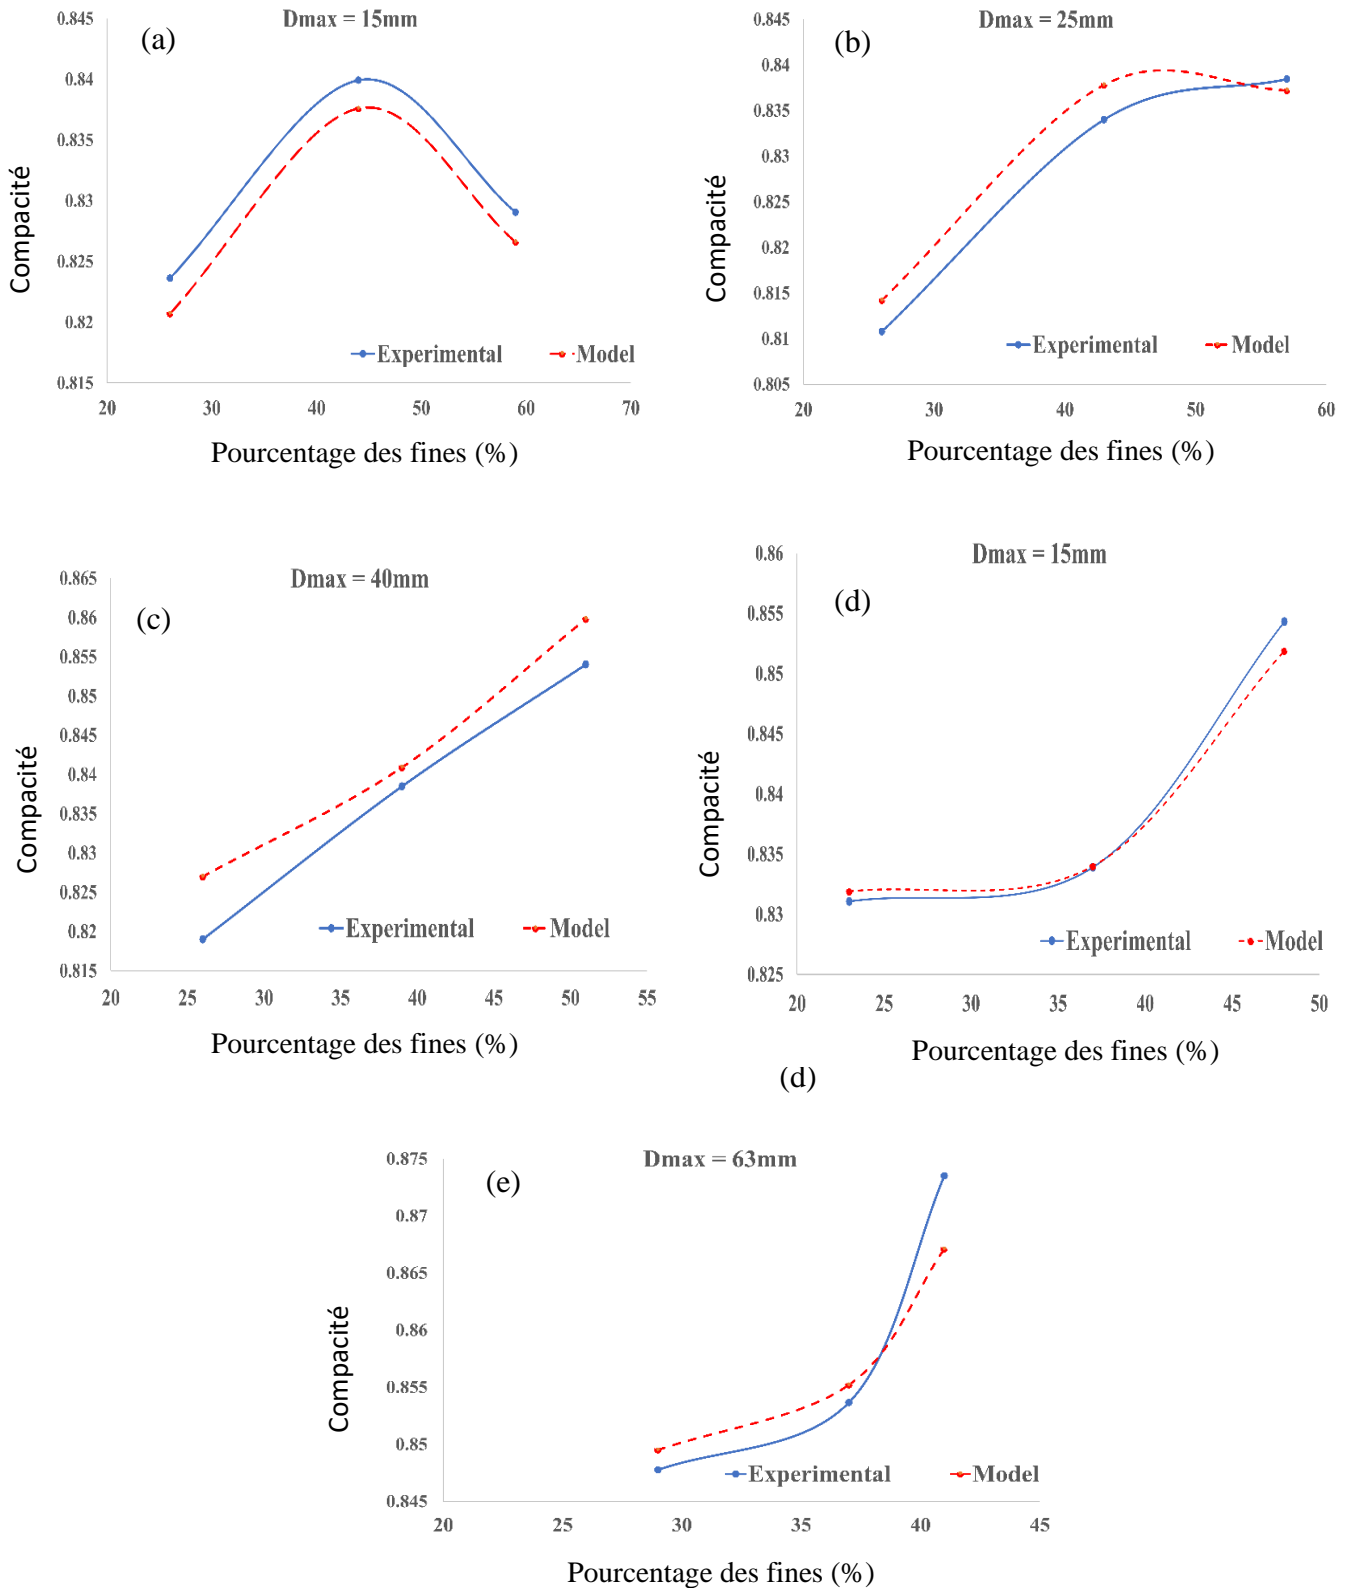


Figure III. 24 Variation de la compacité en fonction de la variation du taux de fine pour : (a) Dmax = 15mm ; (b) Dmax = 25mm ; (c) Dmax = 40mm (d) Dmax = 50mm ; (e) Dmax = 63mm

La Figure III. 25 et la Figure III. 26 indiquent respectivement la variation de la compacité mesurée (expérimentalement) et prédite en fonction de la variation du D_{max} pour différents taux de fines. À travers ces résultats, on remarque l'évolution à la hausse de la compacité granulaire mesurée et prédite en fonction de l'augmentation du D_{max} et cela en fonction de l'augmentation du pourcentage des fines de 25 à 42%. Les deux histogrammes de la Figure III. 25 et Figure III. 26 montrent qu'avec l'augmentation du D_{max} , l'amélioration de la compacité devient plus significative pour des taux de fines plus élevés. Cette amélioration progressive de la compacité en fonction de l'augmentation de D_{max} et de taux de fines est due à l'augmentation progressive des vides intègre granulaires causé par l'augmentation de D_{max} [138]

Dans une autre perspective d'analyse, on peut voir clairement à travers les résultats de la Figure III. 24 et des deux figures (Figure III. 25 et la Figure III. 26) que le modèle de prédiction PSO-RNA développé et optimisé, montre une excellente précision de prédiction de la compacité. Cela se traduit, d'une part, par les mêmes tendances de variation (en fonction des deux paramètres étudiés : D_{max} et le taux de fines), en comparaison avec celles de la variation des valeurs expérimentales, et d'autre part, par le faible écart entre les valeurs des compacités prédites et celles mesurées expérimentalement des mêmes mélanges granulaires.




Figure III. 25 Variation de la compacité expérimentale en fonction du Dmax pour différents taux de fine




Figure III. 26 Variation de la compacité prédite en fonction du Dmax pour différents taux de fine

III.4 Conclusion

Dans cette investigation, un système de prédiction RNA-PSO intelligent hybride a été développé. Cette hybridation a montré son efficacité par rapport à un système RNA de rétropropagation optimisée par l'algorithme de Levenberg-Marquardt.

La richesse de la base de données utilisée (176 vecteurs) ainsi que les larges intervalles de variations des différents paramètres de mélanges granulaires (entrées) ou de la compacité (sortie), offrent au système un bon apprentissage et donc plus de crédibilité.

La modélisation du mélange granulaire, à la fois simple et perspicace, se basant uniquement sur des propriétés géométriques, semble bien refléter et représenter le mélange et a permis aux modèles intelligents un bon apprentissage et de bonne précision de prédiction.

Le modèle RNA-PSO a montré une très bonne capacité de prédiction de la compacité granulaire des mélanges de BCR expérimentés avec un facteur de corrélation significatif ($R = 0,93$) et de bonnes valeurs des indicateurs statistiques (une Erreur quadratique (MSE) avec l'Erreur quadratique moyenne (RMSE) égale à $2,72e^{-05}$ et 0,0052 respectivement, l'Erreur absolue moyenne (MAE) de 0,0042, avec une Erreur moyenne absolue en pourcentage (MAPE) de 0,5030 %)

L'étude de sensibilité du modèle RNA-PSO a montré un comportement habituel de la compacité en fonction de paramètres essentiels de variation, tel que le D_{max} et le taux de fines dans les mélanges granulaires. Cette tendance correspond largement avec la littérature.

Enfin, on peut avancer que le modèle de prédiction de la compacité développé, s'appuyant sur des paramètres géométriques simplement mesurables, peut constituer un outil de prédiction efficace pour des mélanges rentrant dans les fuseaux granulaires étudiés, qui couvrent un domaine d'utilisation très large dans la conception des bétons compactés au rouleau « BCR »

CHAPITRE IV

*Prédiction intelligente des paramètres
essentiels de (BCR) à savoir : la
résistance à la compression, le rapport
E/C et le dosage en ciment*

IV.1 Introduction

La résistance mécanique du BCR demeure un paramètre d'une grande importance dans la conception des barrages. Elle est exploitée pour satisfaire les exigences du calcul structurel et comme indicateur de qualité de résistance et de durabilité [47]. Dans ce contexte, l'ingénieur a souvent besoin d'outils de prédiction de la résistance à la compression « R_c » et cela pour deux raisons à savoir : Prédire R_c pour une formulation de BCR donnée pour des calculs ou bien d'exploiter le modèle de prédiction comme outil d'optimisation dans l'étude de formulation du BCR. La résistance à la compression du BCR dépend d'une diversité de paramètres, les plus importants étant la teneur en eau, le dosage en ciment, le type et les propriétés des fillers et de la qualité des agrégats. Par ailleurs, l'influence du dosage en ciment « D_c » et du rapport eau/ciment « E/C » restent parmi les plus significatives [148]. Pour les bétons conventionnels, plusieurs modèles sont disponibles pour la prédiction de R_c , tel que le modèle ACI [16] ou encore le modèle CEB [149]. Pour les BCR par contre, peu de modèles de prédiction à la résistance mécanique ont été développés. Toutefois, il est à noter qu'une multitude de méthodes de formulation sont utilisées pour l'optimisation des paramètres de formulation (dosage en ciment et rapport E/C) en fonction de la résistance mécanique du BCR. Ces procédés sont souvent basés sur des programmes expérimentaux volumineux avec un nombre de gâchés d'essais important faisant varier les différents paramètres d'influences [28]. Dans son rapport, le comité d'ACI sur les BCR de barrage [13], évoque quelques relations empiriques présentant la variation de R_c en fonction de C et du rapport E/C pour quelques types de granulats. Cependant aucun modèle de prédiction global, impliquant un ensemble de paramètres d'influence sur la résistance n'est présenté. D'autres méthodes se basent sur des approches plus théoriques, utilisant des formules empiriques ou encore des modèles théoriques bien établies, mais toutefois impliquent une caractérisation expérimentale contraignante des différents matériaux constitutifs du BCR. Dans ce contexte, le modèle RENE-LCPC propose la prédiction de R_c en prenant en compte une gamme de paramètres très riche. Ce modèle a été développé pour les bétons courants mais peut être adapté pour les BCR, s'appuyant toutefois sur diverses hypothèses et une multitude d'essais au laboratoire [148]. Dans cette approche, les additions minérales sont considérées comme fillers de remplissage avec une correction proposée en fonction de l'activité pouzzolanique.

Après avoir développé un outil de prédiction de la compacité d'un mélange granulaire dans le chapitre précédent, le présent chapitre propose de concevoir des modèles d'intelligence artificielles pour la prédiction des autres paramètres de la formulation des BCR, notamment les plus important à savoir : le dosage en ciment « Dc » et le rapport E/C. Ces deux paramètres sont étroitement liés et dépendent fortement de la résistance à la compression du BCR souhaitée. Ce travail est réalisé en s'appuyant sur une base de données recueillie sur des rapports d'activité de laboratoire de plusieurs chantiers de construction de barrages algériens.

Ainsi, plusieurs modèles RNA et hybrides RNA-PSO seront développés pour la prédiction de la résistance à la compression en fonction des paramètres de formulation du BCR et d'autre modèles pour prédire le rapport (E/C) et le dosage en ciment « Dc » en fonction des autres paramètres de formulation et de la résistance à la compression souhaitée. Enfin, un programme expérimental riche sur des BCR a été réalisé au laboratoire pour valider les différents modèles développés.

IV.2 Base de données

La base de données a été créée à partir des formulations de BCR issues des rapports d'activités de laboratoire établis pour la construction de quatre (04) barrages algériens (Barrage de *Koudiat-Acerdoun*, Barrage de *Tabellout*, Barrage de *Ouljet-Mellegue* et Barrage de *Boussiaba*). Ces données nous été fournies par l'Agence Nationale des Barrages et Transfères (ANBT). Les rapports d'activité contiennent les informations concernant toutes les formulations de BCR (Caractéristiques de matériaux, dosages et propriétés de BCR) utilisés lors de la construction du barrage. Dans ce qui suit, nous allons présenter succinctement les matériaux utilisés dans la fabrication des BCR des quatre (04) barrages étudiés et leurs propriétés (physiques, chimiques et mécaniques).

IV.2.1 Matériaux et caractéristiques

IV.2.1.1 Matériaux utilisés

IV.2.1.1.1 Granulats

- **Filler**

- *Cas des barrages de Koudiat-Acerdoun, de Tabellout Ouljet-Mellegue et de Boussiaba*

Les fillers utilisés dans la construction des quatre barrages retenus sont de la même provenance, ce sont des fillers calcaires de dimension 0/1mm avec un passant au tamis 80 μ d'environ 85% provenant de la carrière ENG de Constantine obtenue par broyage de roche calcaire. Le pourcentage des fillers utilisés dans le mélange granulaire varie entre 4 et 6%. Le Tableau IV. 1 illustre les principales caractéristiques physico-chimiques des fillers calcaires utilisés Et la Figure IV. 1 présente leur granulométrie laser.

Tableau IV. 1 Principales caractéristiques physico-chimiques des fillers calcaires 0/1

Caractéristiques chimiques				Caractéristiques physiques			
CaCO ₃ (%)	CaO (%)	SiO ₂ (%)	PH	Dureté (MOHS)	Poids spécifique	Densité apparente (g/cm ³)	Indice de réfraction
98	55,18	0,06	9	3	2.7	1,31	1,71




Figure IV. 1 Courbe granulométrique laser des fillers calcaires

- **Sable**

Les sables utilisés dans les constructions des quatre barrages, proviennent du concassage des alluvions de site, ayant les classes granulométriques suivantes :

- De 0/5mm a été utilisée pour les barrages de *Koudiat-Acerdoun, de Tabelout et de Boussiaba (es 70%)*,
- De 0/3 mm a été utilisée pour les barrages de *Ouljet-Mellegue*.

- **Les graviers**

Dans la base de données considérée, différentes fractions granulaires de concassage des alluvions du site ont été utilisées dans les quatre barrages :

- *Koudiat-Acerdoun et Tabelout* : Deux fractions de gravier ont été utilisées ; 5/20 et le 20/50.
- *Boussiaba* : Trois classes granulaires de graviers ont été utilisées ; 5/20, 20/40 et 20/63
- *Ouljet-Mellegue* : Dans ce cas, quatre fractions de gravier ont été considérées : 3/8 , 8/15, 15/25 et le 25/50.

IV.2.1.1.1 Propriétés des matériaux

- ❖ Granulométrie

L'analyse granulométrique de la base de données a été effectuée selon deux normes :

- La norme **NF EN 933-2** a été utilisée pour la séparation mécanique par tamisage des fractions granulaires ayant des granulats de diamètre ($\geq 63 \mu\text{m}$),
- Pour les fractions inférieures granulaires ($<63 \mu\text{m}$) la granulométrie laser a été effectuée selon la norme LS 13 320 XR.

Les courbes granulométriques des différents matériaux utilisés dans les quatre barrages sont illustrés dans les Figure IV. 2, et Figure IV. 5).




Figure IV. 2 Courbes granulométriques (Barrage de Tabelout)




Figure IV. 3 Courbes granulométriques (Barrage de Boussiaba)




Figure IV. 4 Courbes granulométriques (Barrage de Ouljet-Mellegue)




Figure IV. 5 Courbes granulométriques (Barrage de Koudiat Acerdoune)

❖ **Masse volumique absolue et apparente des matériaux de la base de données**

La masse volumique absolue et apparente des différents matériaux ont été mesurées selon les normes NA255 et NF EN 1097-3 respectivement. Le Tableau IV. 2 montre les différentes masses volumiques mesurées pour les quatre barrages de la base de données.

Tableau IV. 2 Masses volumiques des différents granulats

	Barrage	Filler	S 0/3	S 0/5	G 3/8	G 8/15	G 5/20	G 15/25	G 20/50	G 25/50
ρ_{abs} (kg/m ³)	Tabelout	2,71	-	2,73	-	-	2,72	-	2,71	-
	Boussiaba	2,71	-	2,72	-	-	2,70	-	2,70	-
	Ouljet-Mellegue	2,71	2,70	-	2,73	2,71	-	2,72	-	2,71
	Koudiat Acerdoune	2,71	-	2,72	-	-	2,70	-	2,71	-
ρ_{app} (kg/m ³)	Tabelout	2,6	-	2,58	-	-	2,60	-	2,64	-
	Boussiaba	2,6	-	2,67	-	-	2,63	-	2,62	-
	Ouljet-Mellegue	2,6	2,67	-	2,69	2,66	-	2,69	-	2,68
	Koudiat Acerdoune	2,6	-	2,56	-	-	2,56	-	2,57	-

Propriétés mécaniques des graviers Les propriétés mécaniques des différents matériaux ont été identifiées par le test Los Angeles et du Micro-Deval selon les normes **NF EN 1097-2** et **NF EN 1097-1** respectivement. Les résultats obtenus sont regroupés dans le Tableau IV. 3

Tableau IV. 3 Résultats des coefficients de LA et MDE

Coefficients	Barrage	G 3/8	G 8/15	G 5/20	G 15/25	G 20/50	G 25/50
L _A	Tabelout	-	-	26,8	-	25,7	-
	Boussiaba	-	-	≤ 40	-	≤ 40	-
	Ouljet-Mellegue	20,43	20,67	-	20,18	-	20,28
	Koudiat Acerdoune	-	-	25,40	-	24,60	-
M _{DE}	Tabelout	-	-	-	-	-	-
	Boussiaba	-	-	≤ 40	-	≤ 40	-
	Ouljet-Mellegue	21,2	20,3	-	19,9	-	20,1
	Koudiat Acerdoune	-	-	23,8	-	24,5	-

❖ **L'équivalent de sable ES**

Les sables utilisés dans la base de données ont été soumis à la norme P18-598. Le Tableau IV. 4 illustre les différentes valeurs d'équivalent de sable obtenu.

Tableau IV. 4 Résultat d'équivalent de sable des barrages de la base de données

Equivalent de sable E _s (%)	Barrage	S _{0/3} (%)	S _{0/5} (%)
	Tabelout	-	78,8
	Boussiaba	-	79
	Ouljet-Mellegue	79,5	-
	Koudiat Acerdoune	-	78

❖ **La propriété superficielle des graviers**

Les différents matériaux utilisés dans la construction des quatre barrages respectent répondent à la norme NF933-8 de la propriété superficielle exigée.

IV.2.1.1.2 Ciment

Dans la base de données retenue, les ciments suivants ont été considérés :

- **Cas des barrages de Tabelout et Koudiat Acerdoune et de Boussiaba**

Le ciment utilisé provient de la cimenterie ACC de M'Sila, il s'agit d'un ciment CPJ-CEMII 42,5.

- **Cas du barrage**

Le ciment utilisé provient de la cimenterie de Tebessa, il s'agit d'un ciment CEM II 42,5.

- **Cas du barrage de Ouljet-Mellegue**

Le ciment utilisé dans la construction du barrage Ouljet-Mellegue provient de la cimenterie ACC de M'Sila, il s'agit d'un ciment CEM III 42,5 de faible chaleur d'hydratation.

Les différentes propriétés physico-chimiques des ciments utilisés dans la base de données sont reportées dans le Tableau IV. 5 .

Tableau IV. 5 Propriétés physico-chimiques des ciments de la base de données

Barrages	Caractéristiques chimiques					Caractéristiques physiques				Essais mécaniques
	SiO ₂ (%)	Al ₂ O ₃ (%)	Fe ₂ O ₃ (%)	Mgo	CaO	P.S (g/C m ³)	SSB cm ³ /g	Temps de pris		Résistance à 28 jours
								Début	Fin	
Tabelout et Koudiat Acerdoune	17,19	4,17	3,06	1,72	62,17	3,12	3930	150	240	44,5
Boussia	25,4	6,18	2,67	1,38	56,4	3,11	3552	142	190	43,7
Ouljet-Mellegue	11,6	1,86	2,45	0,84	45,55	3,09	4020	190	295	47,5

IV.2.1.1.3 Adjuvant

Dans le cas des quatre barrages, un adjuvant retardateur de prise et un plastifiant réducteur d'eau ont été utilisés ; le Plasti-retard et le Sikaplast HP + de Sika Algérie.

IV.2.1.1.4 Eau de gâchage

Pour la confection de la base des données des quatre barrages, l'eau de gâchage utilisée répond à la norme P 18-303 et satisfait en particulier les conditions mentionnées dans le Tableau IV. 6

Tableau IV. 6 condition d'utilisation de l'eau de gâchage

	Béton précontraint	Béton armé	Béton non armé
Chlorures (g/l)	< 0,5	< 1,0	< 4,5
Nitrates (g/l)	< 0,5		
Sucres, phosphates, Pb, Zn (g/l)	< 0,1		
Sulfates (g/l)	< 2,0		
Alcalins (g/l)	< 1,5		

IV.2.1.2 Choix des paramètres et limite de la base de données

La résistance à la compression du BCR dépend essentiellement de la formulation choisie (dosage des différents matériaux) ainsi qu'elle dépend aussi des caractéristiques physico-chimiques des matériaux utilisés dans la formation. D'après la littérature, et sur la base des

méthodes issues de l'intelligence artificielle, plusieurs travaux de prédictions de la résistance à la compression ont été effectués pour divers types de bétons. Rebouh et al. [96] dans leur investigation ont utilisé un système hybride (réseau de neurone hybridé RNA avec l'algorithme génétique GA) pour prédire la résistance à la compression du béton contenant de la pouzzolane naturelle. Dans cette étude, les dosages en liant, eau, en Pouzzolane, en gravier, et en sable ainsi que l'âge d'écrasement de béton ont été sélectionnés et définis comme paramètres de formulation et d'entrée dans le modèle ayant une influence directe sur la résistance. Dans ce contexte l'utilisation d'un système intelligent basé sur les RNA pour l'estimation de la résistance à la compression du béton compacté au rouleau, a été conduite par Ranjbar et al. [150] qui ont constaté que la résistance à la compression du BCR est influencée directement par le dosage en fines et gros agrégats. Le dosage en ciment, le rapport E/C ainsi que l'âge d'écrasement représentent des facteurs essentiels dans les paramètres d'entrée du modèle. A ce propos, Chakali et al.[151] ont conduit un travail similaire sur l'utilisation de d'un système hybride PSO-RNA pour prédire la résistance à la compression du BCR barrage. Les auteurs précités ont mentionné que la résistance à la compression du BCR barrage dépend essentiellement ; du dosage en eau et en ciment ainsi que de l'âge d'écrasement, de la taille maximale des granulats utilisées, de la compacité du mélange granulaire et du dosage en matériaux granulaire, Divers auteurs chercheurs ont noté l'influence des mêmes paramètres défini sur la résistance à la compression du béton [20,30,32].

Pour la première partie du travail, les paramètres pris en considération à partir de la base de données pour le développement du modèle de prédiction de la résistance à la compression du BCR pour barrage sont : le diamètre maximal des granulats (D_{max}), la compacité du mélange granulaire sec (C), le dosage en ciment (D_c), le dosage en fillers calcaires (D_f), le rapport Eau/Ciment (W/C) et l'âge de l'écrasement (A).

Pour le deuxième modèle de prédiction des paramètres de formulation, le rapport E/C et du dosage en ciment (D_c) sont prédit en fonction des autres paramètres sus-cités : le diamètre maximal des granulats (D_{max}), la compacité du mélange granulaire sec (C), le dosage en fillers calcaires (D_f), la résistance à la compression (R_c) et l'âge de l'écrasement (A).

En ce basant sur ce schéma, une fois les quatre rapports d'activité de laboratoire exploités, 600 vecteurs de données brutes ont été récoltés. Après une analyse et un tri des données, 500 vecteurs, les plus complets ont été retenus.

Ainsi, le Tableau IV. 7 représente quelques exemples représentatifs des données récoltées ainsi que les valeurs minimales et maximales de chaque paramètre.

Tableau IV. 7 Exemples et valeurs limites de formulations de BCR de la base de données

Paramètres	D_{max} (mm)	Compacité é C	Dosage en ciment D_c (Kg/m ³)	Dosage en fillers D_f (Kg/m ³)	Rapport W/C	Age A (Jours)	Résistance f_c (MPa)
1	40	0.84	140	133	0.75	28	15.35
2	50	0.85	110	140	1.05	90	14
3	63	0.85	120	145	0.7	28	14.4
Valeur Min	40	0.80	70	60	0.58	28	4,9
Valeur Max	63	0.90	170	170	1,14	90	24,1

IV.3 Prédiction de la résistance à la compression R_c du BCR

IV.3.1 Modèle "M1" de Réseau de Neurones Artificiel

Dans cette partie, le réseau de neurone de type perceptron multicouche à rétropropagation (BPMLP), le plus utilisé dans le domaine, a été considéré. La base de données (500 vecteurs) a été répartie en trois parties :

- 70% a été utilisée pour l'apprentissage,
- 15% pour le test
- 15% pour la validation.

Le vecteur d'entrée de la base de données a été normalisé selon la même méthodologie adoptée dans la partie I.3.3.1 du chapitre III.

IV.3.1.1 Architecture du RNA

L'architecture du RNA a été développée selon la méthodologie utilisée dans la partie III.3.3.1.1 du chapitre III (une couche d'entrée, une couche cachée et couche de sortie). Sur la base des paramètres de la composition du BCR sélectionnés (D_{max} , C, D_c , D_f , E/C et A), six neurones ont été retenus pour la couche d'entrée. Le neurone de la couche de sortie représente la résistance à la compression « R_c ». Pour définir un modèle RNA avec des meilleures performances, une série de simulations avec variation du nombre de neurones de la couche cachée a été effectuée. L'apprentissage du RNA a été effectué à l'aide de l'algorithme Levenberg-Marquardt. Les meilleurs résultats de prédiction ont été obtenus pour un RNA ayant une architecture de : 6 neurones dans la couche d'entrée, 8 neurones dans la couche cachée et 1

neurone dans la couche de sortie (Figure IV. 6) . Cette architecture du réseau RNA est considérée pour le reste de l'étude.

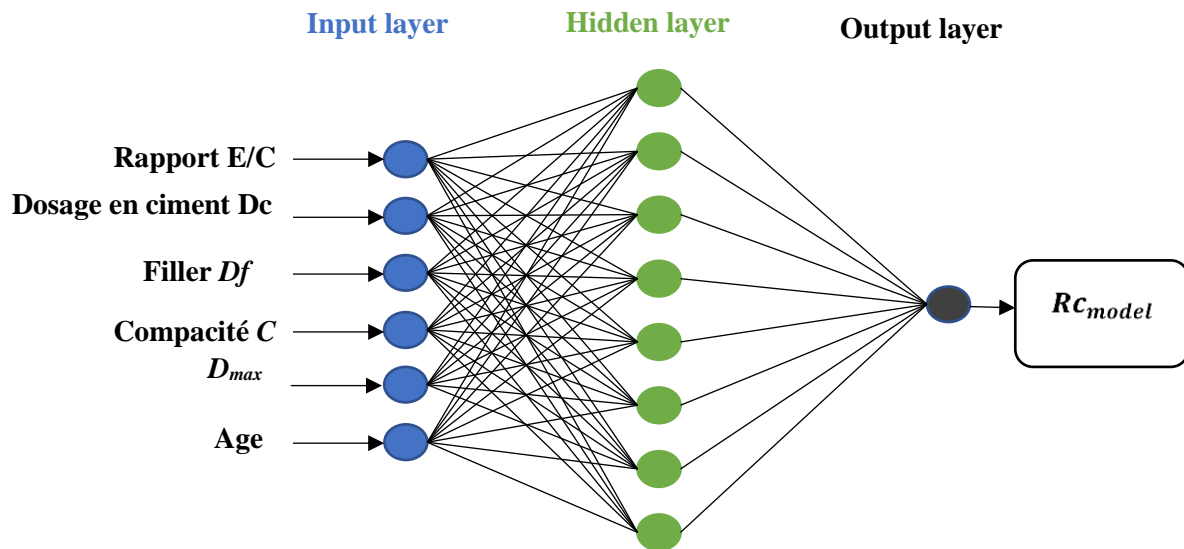


Figure IV. 6 Architecture du modèle de prédiction de la résistance à la compression

IV.3.2 Modèle "M2" hybride RNA-PSO

Dans le but de perfectionner les prouesses du RNA créés, une hybridation par l'algorithme PSO est proposée. Il s'agit d'optimiser les paramètres poids et biais de l'RNA phase d'apprentissage par le métaheuristique PSO. La méthode d'hybridation considérée et la même utilisée dans la partie I.3.3.2 du chapitre III.

Le Tableau IV. 8 illustre les différents paramètres du modèle RNA-PSO présentés pour la prédiction de la résistance à la compression. Selon Alam et al. [145] l'algorithme PSO présente ses meilleures performances avec des coefficients d'accélération C_1 et C_2 compris, respectivement, de 1 à 2,5 et de 2 à 3. Après une variation successive de ces coefficients dans les plages recommandées, les meilleurs résultats ont été obtenus pour $C_1=1,5$ et $C_2= 2,5$. La Figure IV. 7 présente la variation de l'erreur quadratique « RMSE » en fonction du nombre des itérations. Un agrandissement sur les cinquante premières itérations a été effectué pour mettre en évidence l'influence de la taille de population du PSO sur l'erreur de prédiction RMSE du modèle. La meilleure performance a été obtenue pour une population de 400.

Tableau IV. 8 Paramètres du RNA-PSO considérés

RNA			PSO			
Couche d'entrée	Couche cachée	Couche de sortie	Itération	C ₁	C ₂	Population
6	8	1	2000	1,5	2,5	400




Figure IV. 7 Variation de l'erreur quadratique en fonction du nombre d'itérations

IV.3.3 Performance et validation des modèles RNA et RNA-PSO

Les résultats des régressions entre les valeurs expérimentales et celles prédites par les deux modèles développés « RNA » et « RNA-PSO » sont représentés respectivement dans les Figure IV. 8 et Figure IV. 9. Chaque cas montre la régression des 70 % de données réservées pour l'apprentissage, celles du test et de la validation, ainsi que la régression de l'ensemble des données.

La performance des deux modèles développés a été évaluée par plusieurs indicateurs statistiques : MSE (Mean Square Error), RMSE (Root Mean Squared Error), MAE (Mean Absolute Error), MAPE (Mean Absolute Percentag Error) et le coefficient de corrélation R

Le Tableau IV. 9 illustre les résultats des indicateurs de performances des deux modèles RNA et RNA-PSO développés.

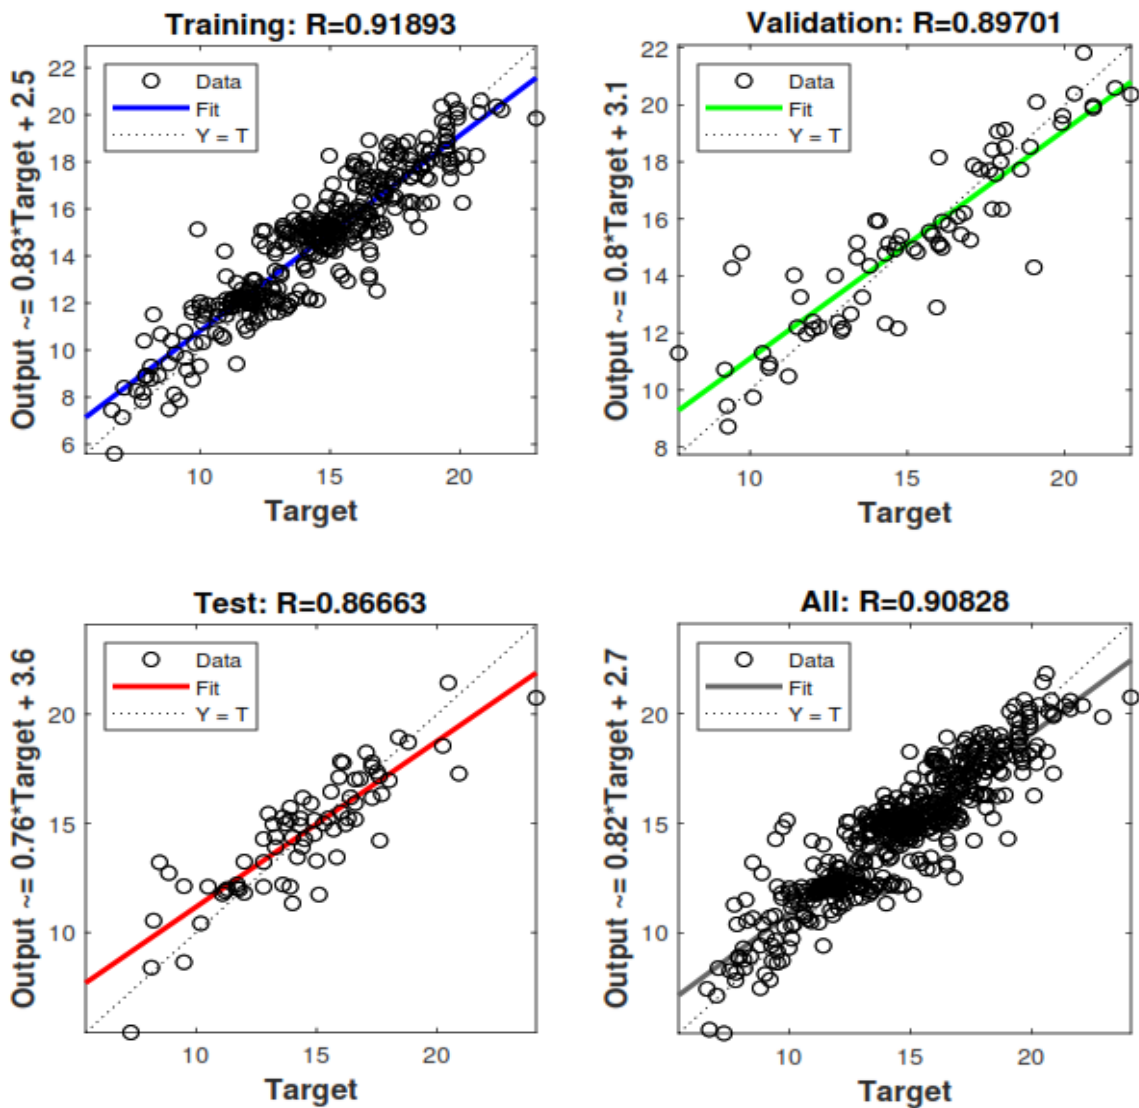


Figure IV. 8 Résultats de régression obtenus par le modèle RNA : (a) Entraînement ; (b) Validation data ; (c) teste ; (d) totale

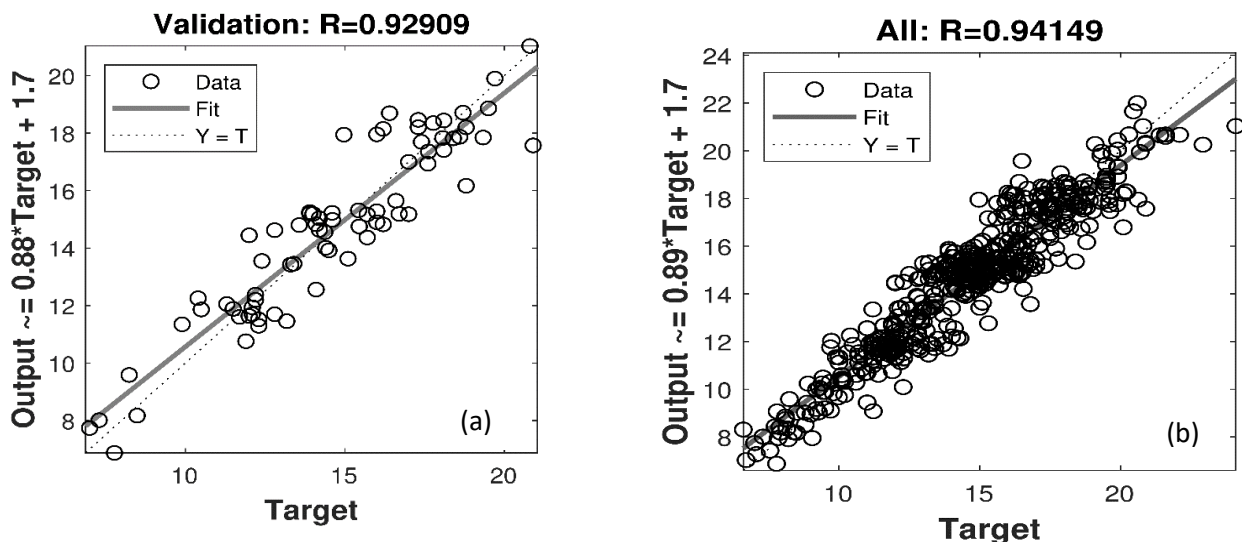


Figure IV. 9 Résultats de régression obtenus par le modèle RNA-PSO : (a) Validation ; (b) totale

Sur la base des résultats de performance obtenus, il est évident que le modèle M2 hybride RNA-PSO présente des résultats plus significatifs par rapport au modèle M1 de RNA. En effet, en comparaison avec le modèle RNA, le modèle RNA-PSO indique une diminution d'environ 32 % de la RMSE, de 17% de la MAE et de 18% de la MAPE. De même une amélioration de 4 % du coefficient de corrélation R a été notée pour la régression du modèle RNA-PSO. A partir de ces résultats, on peut constater l'efficacité de l'algorithme PSO dans l'optimisation des paramètres (poids et biais) du RNA par rapport à une optimisation par l'algorithme de Levenberg-Marquardt LM.

Tableau IV. 9 Performance du RNA et RNA-PSO modèle

Model	MSE	RMSE	MAE	MAPE (%)	R
RNA-PSO	1,4441	1,2017	0,9166	6,5069	0,9415
RNA	2,1296	1,4593	1,1199	8,2433	0,9083

IV.3.4 Influence de la résistance du ciment

Comme il a été mentionné précédemment, les modèles développés (RNA et RNA-PSO) de la prédiction de la résistance à la compression du BCR, s'appuyant sur six (06) paramètres d'entrées ((D_{max} , C, D_c , D_f , E/C et A), ne prennent pas en considération la variation de la résistance à la compression du ciment à 28 jours « R_{C28} », qui joue un rôle très important dans

la résistance du béton [152]. En effet, toutes les méthodes de formulation de béton tiennent en compte de la résistance vraie du ciment. La méthode LCPC, applicable pour les BCR, propose une relation de prédiction de la résistance du béton en fonction de « R_{c28} » (équation 7), qui est basée elle-même sur la relation de Féret [32]. De même, pour les bétons courants, pratiquement toutes les méthodes connues (Bolomey, Dreux Goriss ou encore Walz), proposent des relations similaires [153]. Toutes ces relations mettent en évidence un rapport linéaire entre la résistance à la compression du béton et la résistance du ciment, pour une même composition de béton. Sur la base de cette tendance, et en prenant en considération la résistance du ciment R_{c28} des ciments utilisés dans la confection des BCR de la base de données (selon les rapports d'activité de laboratoire), qui est en moyenne égale à 44 MPa, une relation de correction de la résistance à la compression du BCR prédite par le modèle est proposée par l' Eq IV. 1

$$R_{c_f} = R_{c_{model}} \times \left(1 + \left(\frac{R_{c_{28}} - 44}{44} \right) \right) \quad \text{Eq IV. 1}$$

Avec :

- R_{c_f} : Résistance à la compression finale
- $R_{c_{modèle}}$: Résistance à la compression prédit par le modèle

L'équation Eq IV. 1 proposée permet aux utilisateurs d'introduire leur propre résistance à la compression du ciment afin d'atteindre des résultats plus performant pour prédire la résistance à la compression du (BCR) barrage. Ainsi la valeur finale de la résistance à la compression R_{c_f} du BCR est calculée après correction de $R_{c_{model}}$, en utilisant l'Eq IV. 1, si la résistance du ciment est différente de 44 MPa. La Figure IV. 10 représente le schéma global du modèle de prédiction de la résistance Rc.

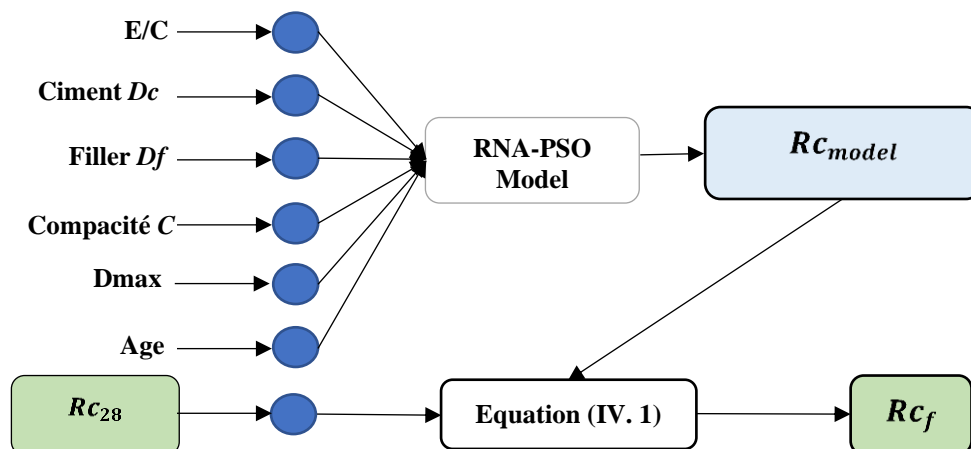


Figure IV. 10 Modèle global de prédiction de la résistance du BCR.

IV.4 Prédiction du rapport Eau/Ciment (E/C) et du dosage en ciment (Dc)

Cette deuxième partie du travail, vise à prédire les deux paramètres E/C et Dc de la formulation de BCR, connaissant sa résistance souhaitée Rc et divers autres paramètres relatifs au mélange granulaire utilisé, Pour ce faire, et après une réflexion objective visant à présenter à l'utilisateur un outil de prédiction couvrant le plus facettes possibles, deux approches de modélisation ont été adoptées :

1. Prédiction individuelle et complémentaire des deux paramètres,
2. Prédiction simultanée des deux paramètres.

IV.4.1 Première approche : Prédiction de C et de E/C individuellement

Dans cette approche deux modèles de RNA (M1 et M2) ont été développées pour la prédiction du dosage en ciment Dc et du rapport E/C. Pour les deux modèles, les 500 vecteurs de données retenus ont été répartis comme suit : Apprentissage (70%), Test (15%), validation (15%).

IV.4.1.1 Modèle M3, M4, M5 de prédiction du dosage en ciment et du rapport E/C

IV.4.1.1.1 Architecture du modèle M3 de prédiction du dosage en ciment

Dans ce modèle, et sur la base des paramètres essentiels de formulation du BCR pris en considération (Dmax, Compacité C, Age, Dosage en fillers Df, Eau/Ciment (E/C), Résistance à la compression Rc, le temps de Vebe) sept (07) neurones ont été considérés dans la couche d'entrée. Le neurone de la couche de sortie représente le paramètre à prédire et qu'il représente dans notre cas le dosage en ciment « Dc ». Pour choisir la meilleure architecture du RNA, une série de simulations a été réalisée à l'aide l'algorithme d'apprentissage Levenberg-Marquardt. Les meilleurs résultats de prédiction ont été obtenus pour un RNA ayant une architecture de : 7 neurones dans la couche d'entrée, 8 neurones dans la couche cachée et 1 neurone dans la couche de sortie (Figure IV. 11).




Figure IV. 11 Architecture du modèle M3 de prédiction du dosage en ciment

Le Tableau IV. 10 illustre les différents paramètres du modèle RNA présentés pour la prédiction de la résistance à la compression.

Tableau IV. 10 Paramètres du RNA considérés pour le modèle M3

RNA		
Couche d'entrée	Couche cachée	Couche de sortie
7	8	1

IV.4.1.1.2 Modèle M4 de prédiction du dosage en ciment avec une deuxième architecture

La méthodologie considéré pour le développement M4 est identique à celle utilisée dans le développement du modèle M3, la seule différence est que le modèle M3 ne prend pas en considération dans les entrées le rapport Eau/Ciment. Les entrées considérées dans ce modèle de prédiction du dosage en ciment sont le Dmax, la Compacité C, Age, Dosage en fillers Df, Résistance à la compression Rc, le temps de Vebe) six (06) neurones ont été considérés dans la couche d'entrée. Le neurone de la couche de sortie indique le dosage en ciment « D_c ». À l'aide l'algorithme d'apprentissage Levenberg-Marquardt, une série de simulation a été effectuée pour atteindre une meilleure architecture du RNA. L'architecture de : 6 neurones dans la couche

d'entrée, 11 neurones dans la couche cachée et 1 neurone dans la couche de sortie a été considéré comme meilleur résultat (Figure IV. 12).

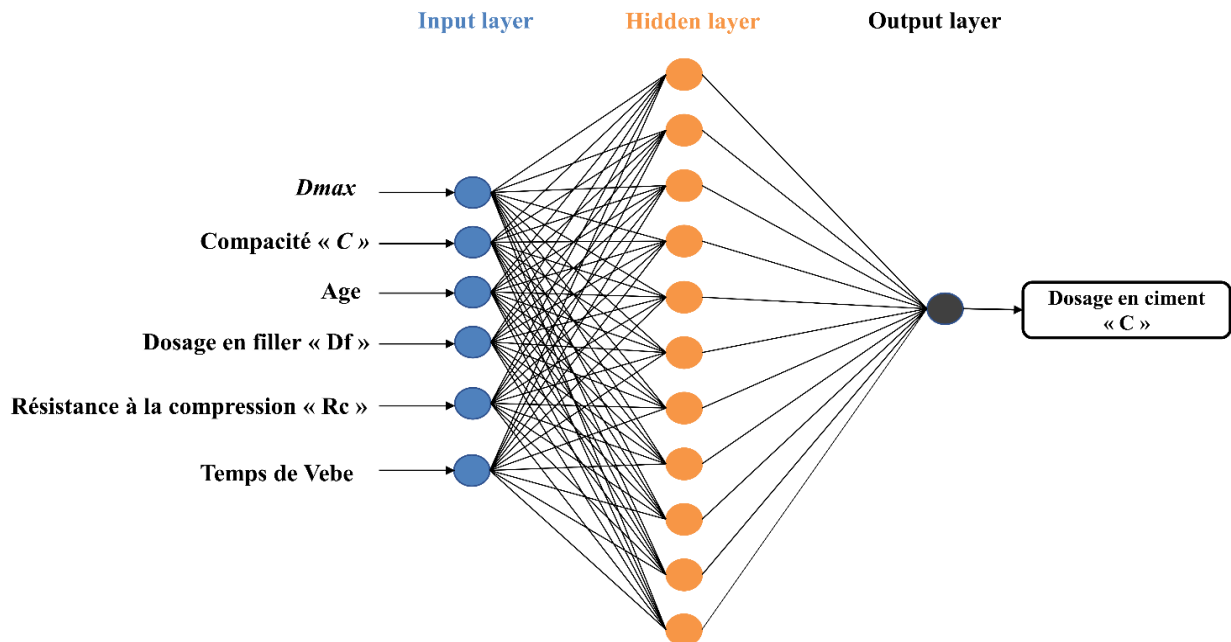


Figure IV. 12 Architecture du modèle M4 de prédiction du dosage en ciment

Le Tableau IV. 11 illustre les différents paramètres du modèle RNA présentés pour la prédiction de la résistance à la compression

Tableau IV. 11 Paramètres du RNA considérés pour le modèle M4

RNA		
Couche d'entrée	Couche cachée	Couche de sortie
6	11	1

IV.4.1.1.3 Architecture du modèle M5 de prédiction du rapport E/C

Dans le deuxième modèle M5 de prédiction du rapport E/C, les paramètres d'entrées (Dmax, Compacité (C), Age, Df, Rc, le temps de Vebe ainsi que le dosage en ciment) ont été considérés comme paramètres. Après plusieurs tentatives d'apprentissage à l'aide de l'algorithme Levenberg-Marquardt avec des variations du nombre de neurone de la couche caché, 8 neurones ont été considérés dans la couche cachée pour une meilleur prédiction du rapport E/C (Figure IV. 13).




Figure IV. 13 Architecture du modèle M5 de prédiction du rapport E/C

Le Tableau IV. 12 illustre les différents paramètres du modèle RNA présentés pour la prédiction de la résistance à la compression.

Tableau IV. 12 Paramètres du RNA considérés pour le modèle M5

RNA		
Couche d'entrée	Couche cachée	Couche de sortie
7	8	1

IV.4.1.2 Performance et validation des modèles M3, M4 et M5

Les Figure IV. 14, Figure IV. 15 et

Figure IV. 16 représentent respectivement les résultats des régressions entre les valeurs de la base de données et celles prédites par les trois modèles de RNA de prédiction du dosage en ciment (modèle M3 et M4) et le modèle M5 de prédiction du rapport E/C. Chaque figure montre la régression des 75 % d'entraînement, 15 % du test, 15 % de validation ainsi que la courbe de régression total.

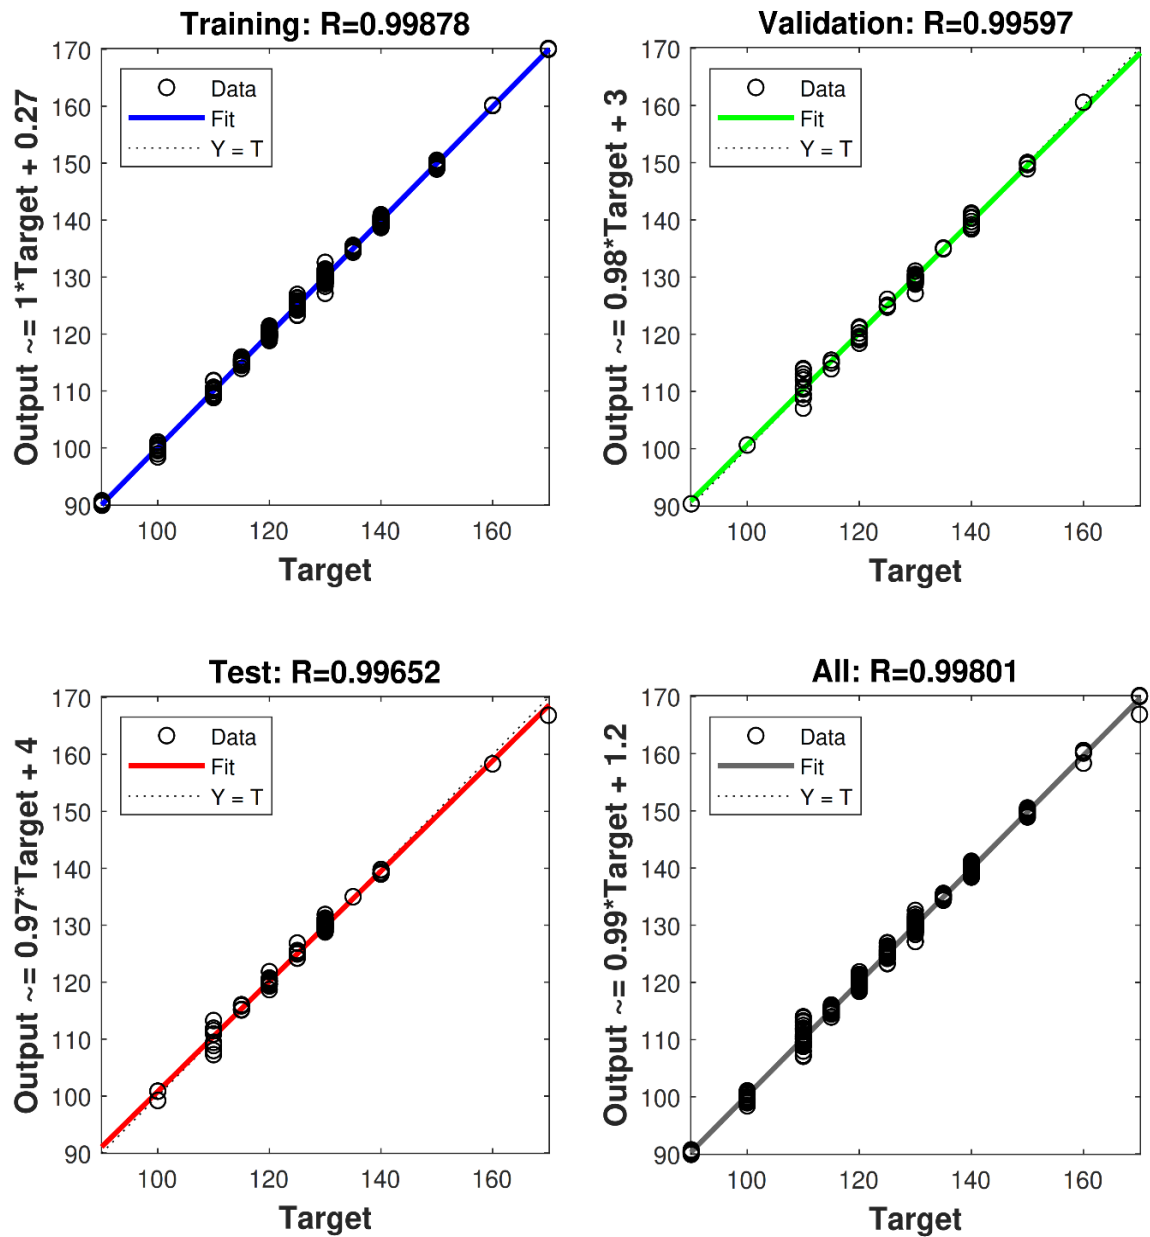


Figure IV. 14 Résultats de régression du modèle M3 obtenus par le modèle RNA : (a) Entraînement ; (b) Validation data ; (c) teste ; (d) totale

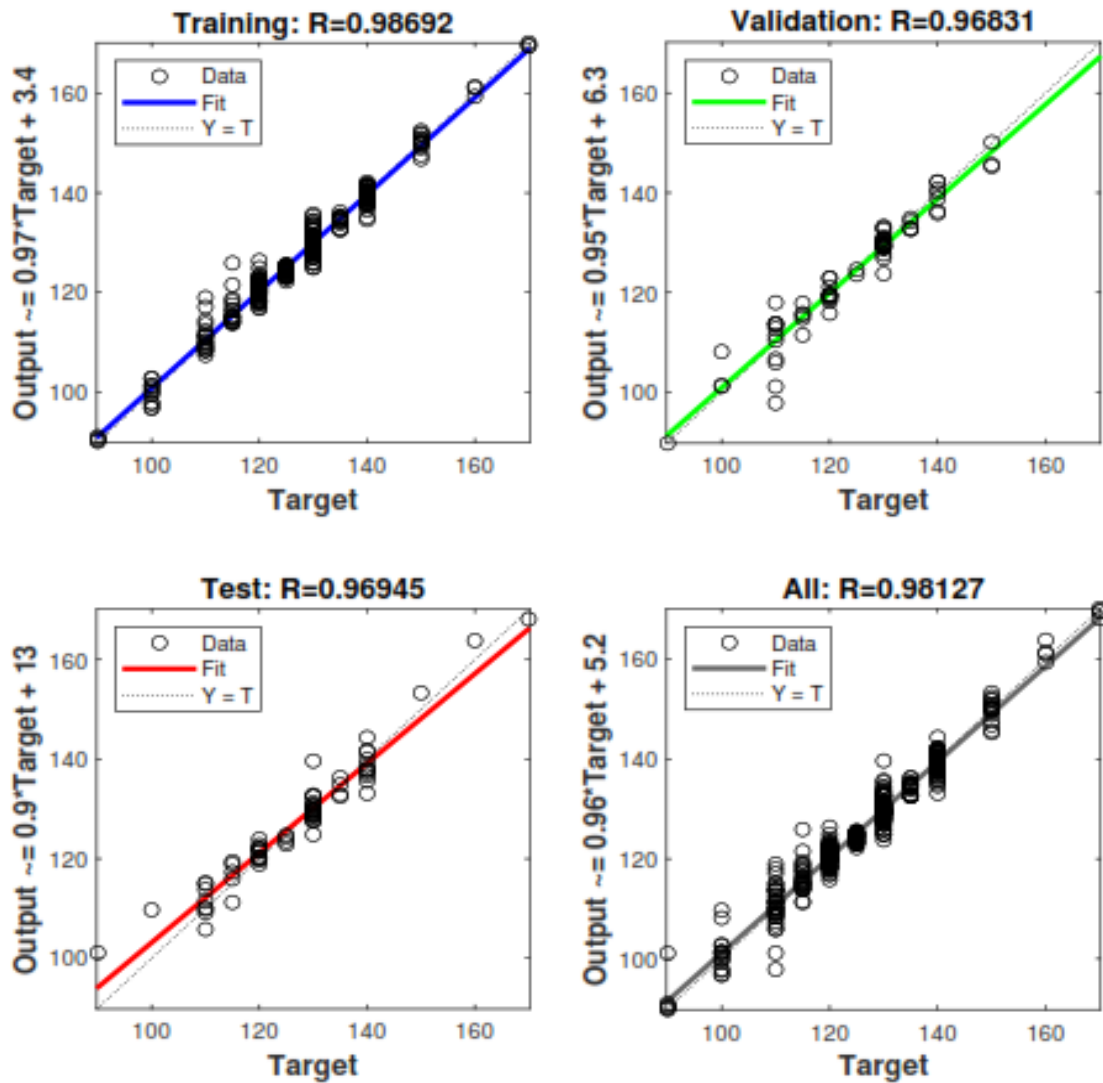


Figure IV. 15 Résultats de régression du modèle M4 obtenus par le modèle RNA : (a) Entraînement ; (b) Validation data ; (c) teste ; (d) totale

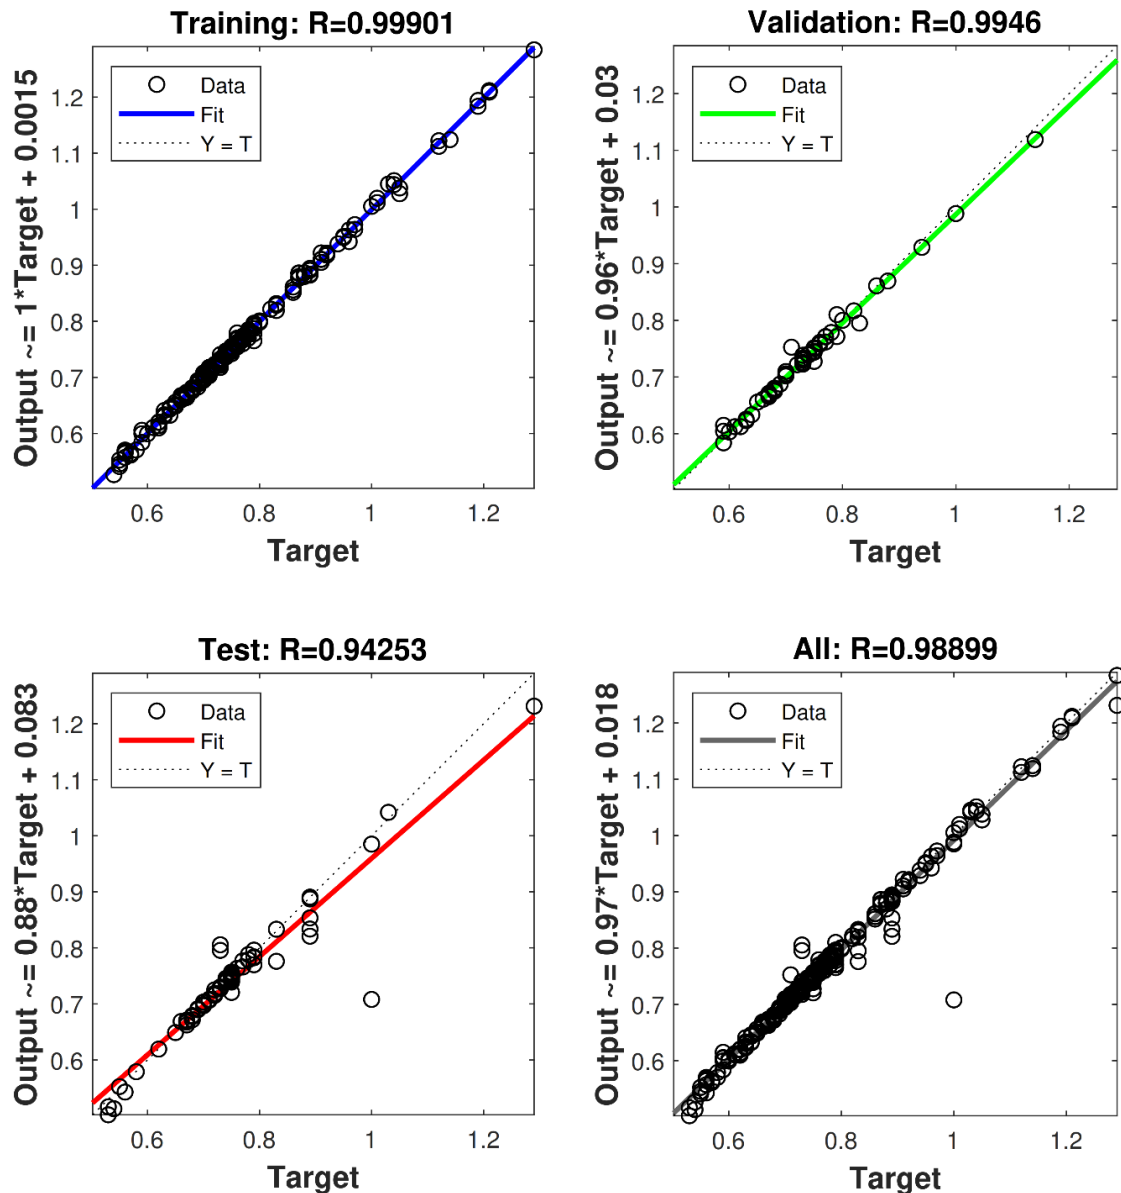


Figure IV. 16 Résultats de régression du modèle M5 obtenus par le modèle RNA : (a) Entraînement ; (b) Validation data ; (c) teste ; (d) totale

Les résultats de performances, selon les indicateurs statistiques, des deux modèles développés M3, M4 et M5 sont présentés dans le **Tableau IV. 13**. Au regard de ces résultats, il apparaît clairement que les modèles RNA "M3","M4" et "M5" ont présenté des résultats très prometteuses en termes de MSE, RMSE, MAE, MAPE et en coefficient de corrélation R.

Tableau IV. 13 Performance des modèles M3, M4 et M5

Model	MSE	RMSE	MAE	MAPE (%)	R
M3	0,6056	0,7782	0,5420	0,4387	0,9980
M4	0,6586	0,7540	1,6261	1,299	0,9812
M5	0,0002	0,0162	0,0053	0,6827	0,9889

IV.4.2 Deuxième approche : Prédiction de C et de E/C simultanément

Dans cette approche, un modèle RNA a été développées en fonction des paramètres essentiels du BCR pour prédire deux paramètres à la fois à s'avoir le rapport E/C et le dosage en ciment D_c . La base de données a été répartie de la même manière que les modèles précédents (70%) pour l'apprentissage, (15%) pour le test et (15%) pour la validation.

IV.4.2.1 Architecture du modèle M6

L'architecture du RNA a été développée selon la méthode utilisée pour les modèles précédents (une couche d'entrée, une couche cachée, une couche de sortie). Dans cette partie, et sur la base des paramètres de la composition du BCR sélectionnés (D_{max} , C, D_f , Rc, Vebe et Age) six (06) neurones ont été considérés dans la couche d'entrée. Dans la couche de sortie deux neurones ont été considérés à savoir le dosage en ciment et le rapport E/C. Pour choisir la meilleure architecture des couches cachées, une série de simulations a été réalisée en utilisant l'algorithme d'apprentissage « Levenberg-Marquardt ». Les meilleurs résultats de prédiction ont été obtenus pour un RNA ayant une architecture de : 6 neurones dans la couche d'entrée, 11 neurones dans la couche cachée et 1 neurone dans la couche de sortie (Figure IV. 17).

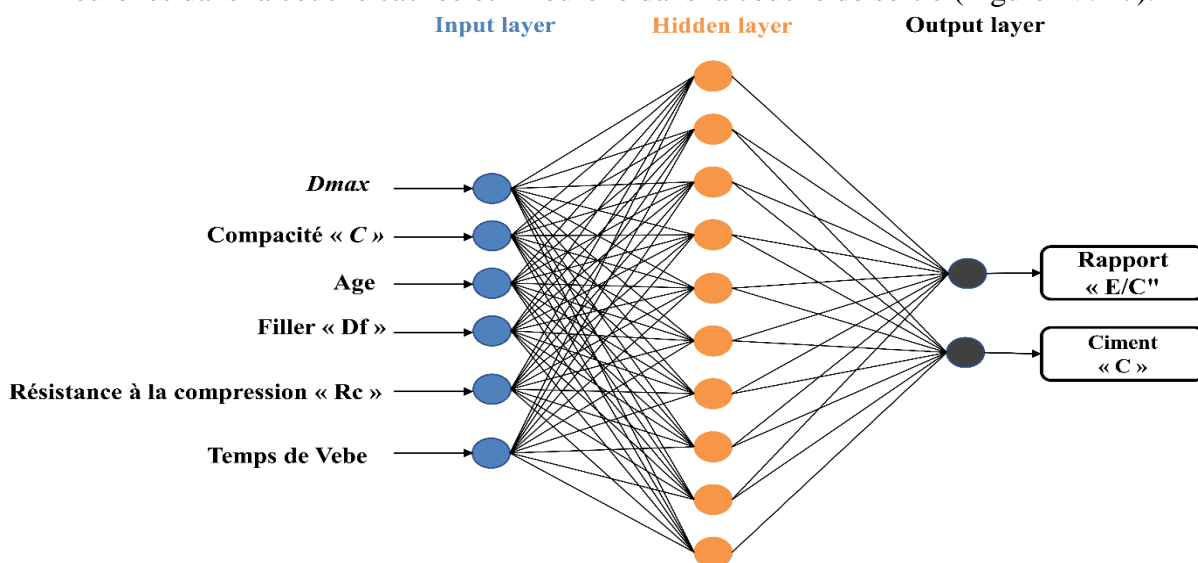


Figure IV. 17 Architecture du modèle de prédiction du rapport "E/C" et du dosage ciment "C".

Le Tableau IV. 14 illustre les différents paramètres du modèle RNA présenté pour la prédiction de la résistance à la compression.

Tableau IV. 14 Paramètres du RNA considérés pour le modèle M6

RNA		
Couche d'entrée	Couche cachée	Couche de sortie
6	11	2

IV.4.2.2 Performance et validation du modèle

La Figure IV. 18 représente les résultats des régressions entre les valeurs de la base de données et celles prédites par le modèle "M6" de prédiction du dosage en ciment du rapport E/C à la fois. La figure montre la régression des 75 % d'entraînement, 15 % du test, 15 % de validation en plus la courbe de régression total.

Un agrandissement a été effectué sur la courbe totale de prédiction pour montrer les deux régressions obtenues dans la même courbe (régression du dosage en ciment et aussi la régression du rapport E/C) (Figure IV. 19).

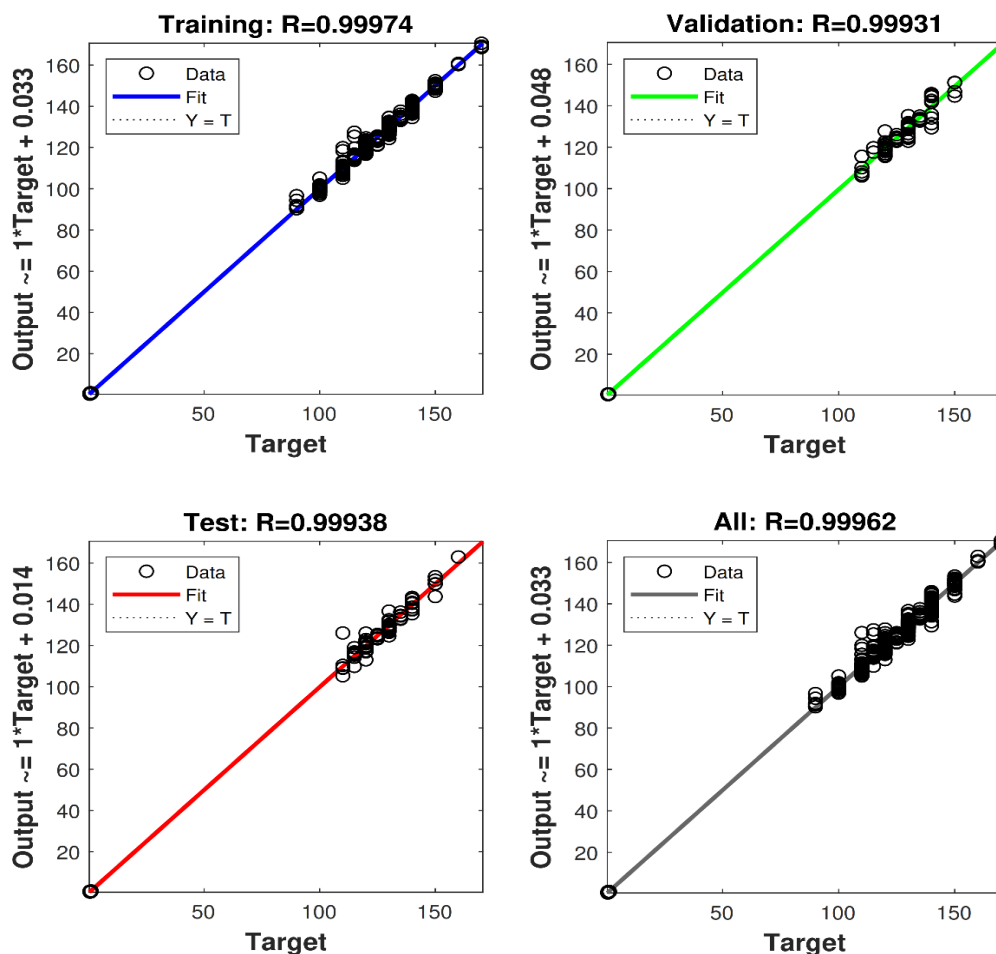


Figure IV. 18 Résultats de régression du modèle de prédiction du rapport E/C et du dosage en ciment obtenus par le RNA : (a) Entraînement ; (b) Validation data ; (c) teste ; (d) totale

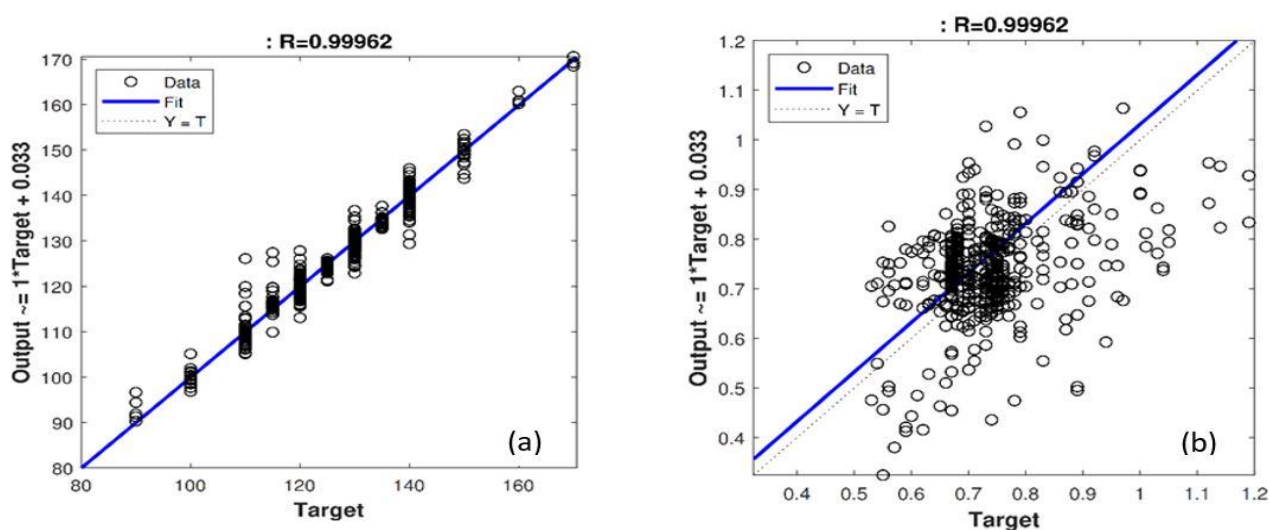


Figure IV. 19 Agrandissement de la courbe de régression totale du modèle M7 de prédiction du E/C et du C : (a) rapport E/C ; (b) Ciment C

Les performances statistiques du modèle RNA de prédiction du "E/C" et du "C" sont présentées Dans le Tableau IV. 15. Sur la base des indicateurs des performances obtenues en termes de MSE, RMSE, MAE, MAPE et en coefficient de corrélation R, il apparait clairement que le modèle développé prédit avec précision le rapport "E/C" et "C".

Tableau IV. 15 Performance du modèle M6 de prédiction du "E/C" et du "C"

Paramètres	MSE	RMSE	MAE	MAPE (%)	R
E/C et C	0.56863589	0.7540795	1.62036321	1.29902922	0,99962

IV.4.3 Validation expérimentale des modèles développés

Dans cette partie de l'étude, après que les modèles développés (M1, M2, M3, M4, et M5) ont été validés par la partie de la base de données réservée, on a opté pour une deuxième validation, qui consiste à comparer les résultats prédits par les modèles avec d'autres résultats expérimentaux issus d'essais de laboratoire. D'autre part, une autre comparaison a été conduite entre les résultats de l'étude expérimentale et ceux obtenus par la méthode développée par le LCPC, qui est une méthode théorique utilisée pour la formulation du béton [12].

Dans le but de tester l'efficacité des modèles RNA et RNA-PSO développé pour la prédiction de la résistance à la compression, le dosage en ciment et le rapport E/C, des essais expérimentaux au laboratoire ont été conduits sur 20 formulations de BCR.

IV.4.3.1 Etude expérimentale

Pour les mélanges granulaires des BCR étudiés, un filler calcaire a été utilisé (0/1 mm avec un passant au tamis 80 μm d'environ 85%) dont les propriétés physico-chimiques sont présentées dans le Tableau IV. 16. Par ailleurs, un sable 0/5 mm, des graviers calcaires (3/8, 8/15, 15/25) et des ballasts 25/40 ou 25/50 ont été utilisés. Leurs principales propriétés sont regroupées dans le

Tableau IV. 17. Les proportions des différents granulats ont été déterminées pour obtenir des mélanges granulaires dont les courbes sont incluses au mieux dans le fuseau granulométrique de référence (Figure IV. 20). La Figure IV. 20 illustre un exemple de mélanges granulaire utilisé.

Tableau IV. 16 Caractéristiques physico-chimiques des fillers calcaires 0/1.

Caractéristiques chimiques			Caractéristiques physiques		
CaCO ₃ (%)	CaO (%)	SiO ₂ (%)	Poids spécifique (t/m ³)	Densité apparente	Indice de réfraction
98	55,18	0,06	2,7	1,31	1,71

Tableau IV. 17 Caractéristiques physico-mécaniques des granulats utilisés.

Granulats	Los Angeles coefficient « LA »	Coefficient d'Aplatissement « AP »	Absorption « Ab » (%)	Masse volumique (t/m ³)
Sable 0/5	-	-	0,27	2,72
Gravier 3/8	22	23	0,66	2,71
Gravier 8/15		17	0,73	2,69
Gravier 15/25	21	13	0,7	2,68
Ballast 25/50		5	-	2,69




Figure IV. 20 Courbes granulométriques des mélanges granulaires.

Par ailleurs, un ciment Portland a été utilisé de type CEM II/42.5 avec une résistance à la compression à 28 jours de 50.1 MPa et une finesse de 4156 g/cm², contenant 17 % d'ajout calcaire provenant d'une cimenterie locale. Sa composition chimique est présentée dans le

Tableau IV. 18. Par ailleurs, un superplastifiant à base de polycarboxylates modifiés a été utilisé afin d'avoir la consistance recherchée des mélanges.

Tableau IV. 18 Composition chimique du ciment.

Composants	SiO ₂	Al ₂ O ₃	Fe ₂ O ₃	CaO	MgO	SO ₃
Pourcentage (%)	17,19	4,17	3,06	62,17	1,72	2,33

Les 20 formulations de BCR considérées, présentées dans le Tableau IV. 19, sont obtenues par variation des paramètres principaux utilisés comme entrées dans le modèle développé (D_{max} , C, D_c , D_f , and E/C). La variation de ces paramètres a été conduite pour refléter au mieux la base de données étudiée. En premier lieu, la compacité « C » des différents mélanges granulaires à sec a été mesurée au laboratoire selon la norme NF EN 13286-5. Après gâchage des mélanges BCR, leur consistance a été déterminée par l'essai VeBe selon la norme ASTM C1170-91. Le temps VeBe a été maintenu entre 18 et 22s. Ainsi, pour chaque formulation, six moules cylindriques de dimension 16 × 32 ont été mises en place avec un compactage sous une masse et vibration selon la norme ASTM C1176. Après 24h les échantillons sont démoulés et conservés dans un bac d'eau à une température de 20±2°C. Après 28 et 90 jours la résistance à la compression a été mesurée selon la norme EN 12930-3. La Figure IV. 21 illustre des photos de l'étude expérimentale




Figure IV. 21 Photos de l'étude expérimentale : (a) Vérification de l'absence d'affaissement et calcul du temps de VEBE ; (b) Spécimens de RCC ; (c) Conditionnement des spécimens avant l'essai ; (d) Essai de résistance à la compression.

Tableau IV. 19 Compositions de BCR étudiées.

Désignation	Granulat D max (mm)	Fillers calcaires (Kg/m ³)	Ciment (Kg/m ³)	Rapport E/C	Sable (Kg/m ³)	Gravier (Kg/m ³)	Ballast Kg/m ³)
BCR(40)1	40	120,75	145	0,70	906,835	796,80	407,52
BCR(40)2		120,75	145	0,80	906,835	796,80	407,52
BCR(40)3		120,75	145	0,85	906,835	796,80	407,52
BCR(40)4		138,24	130	0,70	911,469	810,89	410,16
BCR(40)5		138,24	130	0,80	911,469	810,89	410,16
BCR(40)6		138,24	130	0,85	911,469	810,89	410,16
BCR(40)7		150,72	115	0,65	920,70	807,55	414,32
BCR(40)8		150,72	115	0,70	920,70	807,55	414,32
BCR(40)9		150,72	115	0,75	920,70	807,55	414,32
BCR(40)10		150,72	115	0,80	920,70	807,55	414,32
BCR(50)1	50	123,65	145	0,70	928,621	815,95	417,31
BCR(50)2		123,65	145	0,80	928,621	815,95	417,31
BCR(50)3		123,65	145	0,85	928,621	815,95	417,31
BCR(50)4		138,81	130	0,70	915,21	814,22	411,85
BCR(50)5		138,81	130	0,80	915,21	814,22	411,85
BCR(50)6		138,81	130	0,85	915,21	814,22	411,85
BCR(50)7		150,06	115	0,70	916,65	803,99	412,49
BCR(50)8		146,03	115	0,75	905,38	796,38	407,42
BCR(50)9		150,06	115	0,80	916,65	803,99	412,49
BCR(50)10		150,06	115	0,85	916,65	803,99	412,49

IV.4.3.2 Méthode LCPC

La méthode LCPC [30] se base sur une équation empirique globale (Eq IV. 2) de prédiction de la résistance à la compression et du volume de la pâte. Cette équation prend en considération plusieurs paramètres tel que la constante K_g reliée au mélange granulaire utilisé, la résistance du ciment à 28 jours « R_{c28} », le paramètre $d(t)$ reflétant l'âge du béton, le facteur EMP calculé par l'Eq IV. 3 en fonction de D_{max} et de g^* et g (paramètre de compacité du mélange granulaire). Par ailleurs, l'équation de prédiction globale prend en considération le volume de ciment V_c , le volume de l'eau V_e ainsi que le volume de l'air occlus V_a .

$$f_c(t) = K_g R_{c28} \left[d(t) + \left(\frac{V_c}{V_c + V_e + V_a} \right)^{2,85} \right] EMP^{-0.13} \quad \text{Eq IV. 2}$$

$$EMP = D_{max} \left(\sqrt[3]{\frac{g^*}{g}} - 1 \right) \quad \text{Eq IV. 3}$$

IV.4.3.3 Résultats et discussion

IV.4.3.3.1 Modèle M2, M3, M4 et M5 de la prédiction de la résistance à la compression, le rapport E/C et le dosage en Ciment

Afin de valider les résultats des modèles RNA et RNA-PSO développés pour la prédiction de la résistance à la compression, le dosage en ciment et le rapport Eau/Ciment de BCR, une étude comparative a été réalisée. Dans cette investigation, les résultats de prédiction des modèles finals du RNA et RNA-PSO ont été confrontés avec ceux de l'étude expérimentale de validation pour les mêmes formulations. Les Figure IV. 22 , Figure IV. 23 présentent une comparaison entre les résistances expérimentales et celles prédites par le modèle RNA-PSO et par la méthode LCPC, respectivement. Les indices de performances (R^2 et RMSE) des deux corrélations sont regroupés dans le Tableau IV. 20.




Figure IV. 22 Régression linéaire entre les résultats expérimentaux et ceux simulés le RNA-PSO.




Figure IV. 23 Régression linéaire entre les résultats expérimentaux et ceux simulés par la méthode LCPC.

Tableau IV. 20 Paramètres statistiques des régressions.

Model	RMSE	R ²
RNA-PSO ("M2")	1.45	0.849
LCPC	2.70	0.473

Au regard des Figure IV. 23 et IV. 23, on peut déduire que le modèle RNA-PSO a donné des résultats plus performants par rapport à la méthode LCPC pour la prédiction de la résistance des BCR étudiés. En effet, un coefficient de détermination R^2 de l'ordre de 0.47 a été obtenu avec une erreur quadratique RMSE de 2,70. Le modèle RNA-PSO a mis en évidence une corrélation significative avec un coefficient de détermination R^2 de l'ordre de 0,85 et une valeur de RMSE de 1.45. En comparaison avec les résultats de la méthode LCPC, une amélioration du facteur de détermination de 80% ainsi qu'une diminution de l'erreur quadratique de 45% ont été notées. Ceci montre l'efficacité du modèle RNA-PSO développé pour la prédiction de la résistance des BCR. Cependant, on constate que les valeurs des résistances prédites par le modèle RNA-PSO sont légèrement sous-estimées par rapport aux valeurs expérimentales. Cette sous-estimation de l'ordre de 6% en moyenne (estimée en comparant la droite de régression avec la droite $Y=X$), reste néanmoins peu significative, et peut être expliquée par les quelques différences mineurs en termes de matériaux et mise en œuvre et qui ne sont pas prises en

considération, comme paramètres d'entrée dans modèle, tel que le mode de compactage du béton ou encore le type et le dosage en superplastifiant. Didouche et al. [154] constatent une variation de résistance variable de 8,5 à 10 MPa en modifiant le dosage de 0,6 à 1,5 % de deux superplastifiants (Résine mélanine et polycarboxylate). Dans notre cas, le dosage en superplastifiant n'est pas très variable mais le type n'est pas le même pour les bétons de la base de données et ceux de l'étude expérimentale de validation. Par ailleurs, pour les bétons de la base de données, les éprouvettes ont été compactées à l'aide d'un marteau à percussion selon norme ASTM C1435-99, alors que dans notre cas expérimental nous avons adopté la norme ASTM C1176-92 où une table vibrante est utilisée. Même si les deux méthodes de compactages sont normalisées, elles restent différentes. Il est à noter que la mise en œuvre des éprouvettes en béton influe directement sur la résistance à la compression [155]. Şengün et al. [156] ont démontré que la présence de 5% de vides dans le béton dû à un compactage incomplet, peut entraîner une perte de résistance jusqu'à 30%.

L'erreur de la prédiction recensée par le modèle RNA-PSO demeure toutefois limitée, d'autant plus que la méthode de mesure de la résistance à la compression (selon la norme EN 12390-3) elle-même, tolère une valeur d'erreur de 11,7 % dans des conditions de reproductibilité d'essais.

L'investigation conduite a montré l'importance de l'utilisation du fillers calcaires comme ajout de remplissage pour une amélioration considérable des propriétés de (BCR) et pour une diminution importante dans le prix de construction par la réduction du taux de ciment, du côté environnementale, l'utilisation des fillers calcaires a contribué dans la diminution du taux de poussière engendrée par les carrières de concassage qu'il représente une quantité conséquente en Algérie. Le modèle RNA-PSO a montrée l'importance de l'utilisation des pourcentages des fillers calcaires comme entrée pour une prédiction de la résistance à la compression du (BCR) barrage.

Afin de tester l'efficacité des modèles de RNA développés pour la prédiction du rapport E/C et du dosage en ciment D_c , les résultats de l'étude expérimentale (Tableau IV. 19) effectuée au laboratoire ont été utilisés et confrontés avec ceux prédits par les différents modèles. Une deuxième comparaison a été effectuée avec la méthode développée par LCPC.

La Figure 24 illustre les résultats du modèle LCPC de prédiction de ciment et du rapport E/C en fonction des résultats expérimentaux.

Les Figure IV.25, Figure IV.26, Figure IV.27 présentes respectivement les corrélations en résultats du modèle RNA de prédiction de ciment ("M3" et "M4") et du rapport E/C ("M5") et ceux des formulations des BCR de l'étude expérimentale.

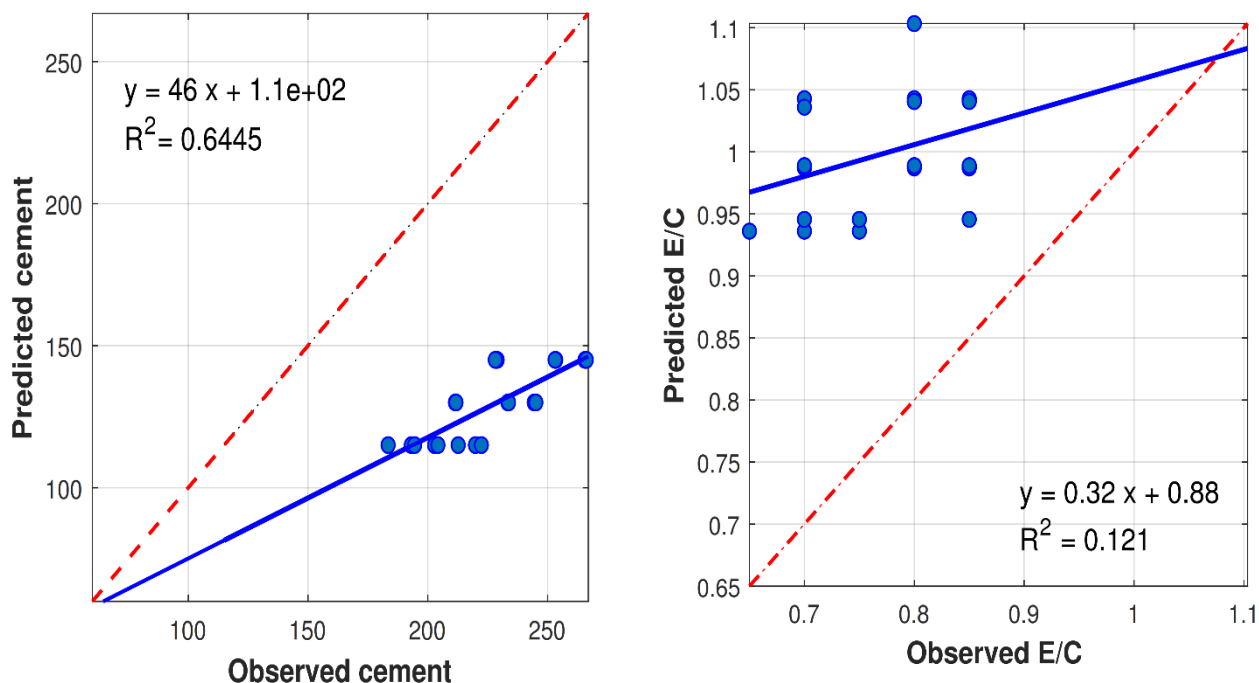


Figure IV. 24 Régression linéaire entre : (a) le ciment expérimental et prédit par le LCPC ; (b) le rapport E/C expérimentale et prédit par le LCPC




Figure IV. 25 Régression linéaire entre le ciment expérimental et prédit par le RNA (modèle "M3")




Figure IV. 26 Régression linéaire entre le ciment expérimental et prédit par le RNA ("M4")




Figure IV. 27 Régression linéaire entre le rapport E/C expérimental et prédit par le RNA ("M5")

Afin d'évaluer les résultats, les indices de performances (R^2 et RMSE) des différentes corrélations ont été calculés et présentés dans le Tableau IV. 21.

Tableau IV. 21 Performances des modèles "M3", "M4", "M5" et du modèle LCPC

	Model	RMSE	R^2
RNA	Ciment ("M3")	4,7610	0,8333
	Ciment ("M4")	5,9966	0,8827
	E/C ("M5")	0,0285	0,8272
LCPC	Ciment	15,013	0,6445
	E/C	0,2288	0,121

D'après le Tableau IV. 21 On constate que le modèle RNA est plus efficace pour la prédiction du dosage en ciment et du rapport E/C des BCR étudiés. En effet, un coefficient de détermination R^2 de l'ordre de 0,64 et de 0,12 avec des erreurs quadratiques RMSE élevées de 15,013 et de 0,2288 ont été obtenus dans la prédiction du dosage en ciment et du rapport E/C respectivement. Par contre, les modèles de RNA ont montré des corrélations prometteuses avec des coefficients de détermination R^2 de l'ordre de 0,833, 0,888 et de 0,827 et des valeurs de RMSE de 4,76, 5,996 et de 0,082 ont été par les modèles "M3", "M4" et "M5" respectivement. En comparaison avec les résultats de la méthode LCPC, un perfectionnement de 23 et de 85% du facteur de détermination ainsi qu'une diminution de l'erreur quadratique de 68% et de 87% ont été observées respectivement dans la prédiction du dosage en ciment et du rapport E/C. Ceci montre l'efficacité des modèles RNA développées pour la prédiction du dosage en ciment Dc et du rapport E/C.

IV.5 Conclusion

Au cours de cette étude, des systèmes de prédiction intelligent, utilisant deux métaheuristiques : Réseaux de neurone « RNA » et les algorithmes de essais de particules « PSO », ont été développés pour la prédiction des paramètres importants de la formulation du BCR (Résistance à la compression, rapport E/C et dosage en ciment).

La diversité de la base de données utilisée (500 vecteurs) ainsi que les larges intervalles de variation des différents paramètres de formulation (entrée) et de la résistance (sortie), offrent aux systèmes un bon apprentissage et donc plus de crédibilité.

Les systèmes développés RNA et (RNA-PSO) ont montré de très bonnes capacités de prédiction de la résistance à la compression, le dosage en ciment ainsi que le rapport E/C des BCR expérimentés. En comparaison avec les résultats obtenus par la méthode LCPC, qui restent peu précises.

Le modèle M2 développé et validé pour prédire la résistance à la compression du BCR en fonction des différents paramètres de sa formulation, constitue un outil de taille dans la conception des BCR.

Les deux approches développées pour la prédiction du rapport E/C et du dosage en ciment D_c , offre à l'utilisateur une bonne souplesse dans l'étude de formulation du BCR. En effet, les quatre modèles développés (M3, M4, M5 et M6) permettront de prédire chaque un des deux paramètres individuellement ou les deux simultanément, en fonction des propriétés des matériaux et de la résistance du BCR souhaitée.

CHAPITRE V

*Méthodologie globale de formulation
du BCR*

V.1 Introduction

L'approche de l'intelligence artificielle a été considérée dans notre étude pour le développement des modèles de prédiction des paramètres essentiels de BCR barrage à savoir ; la compacité granulométrique, la résistance à la compression, le dosage en ciment ainsi que le rapport eau/ciment. Cette étude a été conduite sur la base d'une méthode de formulation bien structurée et développée dans son contexte.

L'investigation de ce chapitre présente les différentes étapes suivies pour le développement de la méthodologie de formulation de BCR, principalement présentée en deux phase de conceptions :

- ✓ Optimisation du mélange granulaire,
- ✓ Prédiction de la résistance à la compression, le dosage en ciment D_c et du rapport E/C.

V.2 Phase I : Optimisation du mélange granulaire

La méthode propose un fuseaux granulométrique [143,144] pour couvrir une large gamme de courbes granulométriques destinés à la réalisation des barrages et des chaussées en BCR (figure V.3). L'utilisateur, après avoir choisi les différents matériaux entrant dans le mélange granulaire désirée et après les avoir caractérisées géométriquement (par essais de granulométrie), il lui est demandé de composer un mélange granulaire entrant dans le fuseau de référence. Cette étape est réalisée exclusivement par l'utilisateur par le biais d'un calcul simple à l'aide d'un tableur. Une fois la courbe à l'intérieur du fuseau, l'utilisateur la modélise pour faire sortir les différents paramètres géométriques de son mélange (D_{max} , d_{10} , d_{30} , d_{50} , d_{60} , d_{80} , C_u , C_c), ainsi que le pourcentage de filler utilisé.

Ces derniers paramètres sont utilisés comme paramètres d'entrée dans le modèle "M1, de prédiction de la compacité du mélange « C ». Ainsi l'opération est répétée autant de fois que nécessaire jusqu'à obtention d'une compacité optimale souhaitée. Les procédures de la phase I d'optimisation du mélange granulaire ont été représentées dans la Figure V. 1.

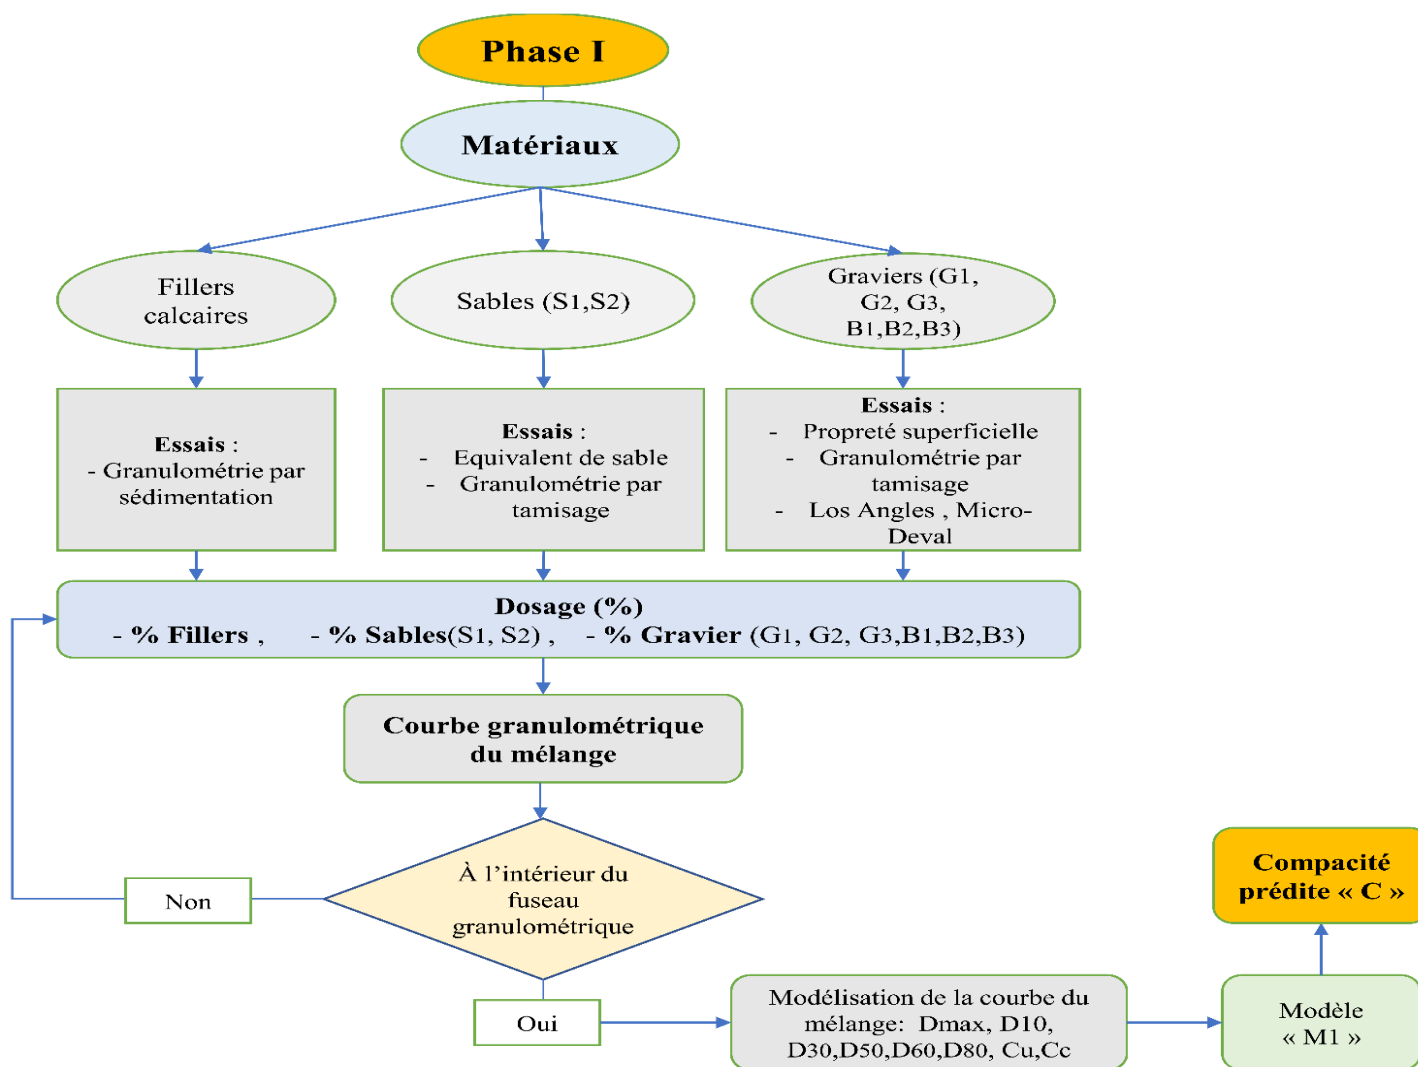


Figure V. 1 Organigramme de la méthodologie de prédiction de la compacité granulométrique

V.2.1 Exemples de simulation de la phase I

V.2.1.1 Matériaux

Dans ce procédé de simulations, nous avons choisi les matériaux utilisés dans le chapitre III, section III.2.1. La Figure V. 2 rappelle la granulométrie des différents matériaux considérés.




Figure V. 2 Courbes granulométriques des différents matériaux utilisés dans le modèle de prédiction de la compacité

Les Figure V. 3 et Figure V. 4 illustrent respectivement un exemple sur le mélange granulométrique applicable aux BCR pour barrages et aux routes.




Figure V. 3 Exemple d'un mélange granulométrique utilisé pour barrage en BCR




Figure V. 4 Exemple d'un mélange granulométrique utilisé pour route en BCR

V.2.1.2 Mélanges granulaires

Après la variation des différentes fractions granulométriques, 05 mélanges ont été retenus, dont les courbes entrent dans les fuseaux granulaires d'étude. Les proportions des différents matériaux utilisés sont regroupées dans le Tableau V. 1.

Tableau V. 1 Exemples sur les pourcentages des fractions granulaires de cinq (05) mélanges granulométriques

Mélanges	Filler 0/1	Sable 0/2	Sable 0/5	Gravier1 3/8	Gravier2 8/15	Gravier3 15/25	Ballast1 25/40	Ballast2 25/50	Ballast3 25/63
1	7	15	20	18	20	8	12	-	-
2	5	7	8	25	15	18	22	-	-
3	7	10	12	19	20	13	-	17	-
4	7	6	10	17	25	16	-	19	-
5	7	10	15	15	18	20	-	-	15

V.2.1.3 Modélisation des mélanges : Paramètres d'entrée

Le Tableau V. 2 illustre respectivement les paramètres d'entrée du modèle "M1" des cinq (05) mélanges granulaires du Tableau V. 1.

Tableau V. 2 Exemples sur les paramètres d'entrée choisis pour le modèle "M1"

Mélanges	Fillers calcaires (%)	D _{max}	D ₁₀	D ₃₀	D ₅₀	D ₆₀	D ₈₀	C _u	C _c
1	7	40	0,164	1,306	4,517	7,602	17,889	46,354	1,368
2	5	40	0,243	4,328	11,593	16,434	26,029	67,630	4,691
3	7	50	0,167	3,551	7,530	10,676	21,289	63,572	7,033
4	6	50	0,190	4,962	9,947	12,812	23,758	67,391	10,107
5	7	63	0,178	2,668	9,947	15,177	21,914	85,264	2,635

V.2.1.4 Prédiction de la compacité "C" avec le modèle "M1" et le développement d'une interface utilisateur

Dans cette partie, la compacité des 05 mélanges granulaires a été précitée à l'aide du modèle "M1", Afin de faciliter la tâche des utilisateurs, une interface visuelle basée sur le modèle de prédiction "M1" a été développée (Figure V. 5), en utilisant la fonctionnalité "app designer" du logiciel Matlab 2021. L'utilisateur doit introduire les valeurs des différents paramètres à savoir (Dmax, d10, d30, d50, d60, d80, Cu, Cc). En validant sur le bouton "Calculate". La valeur de la compacité prédite s'affiche.

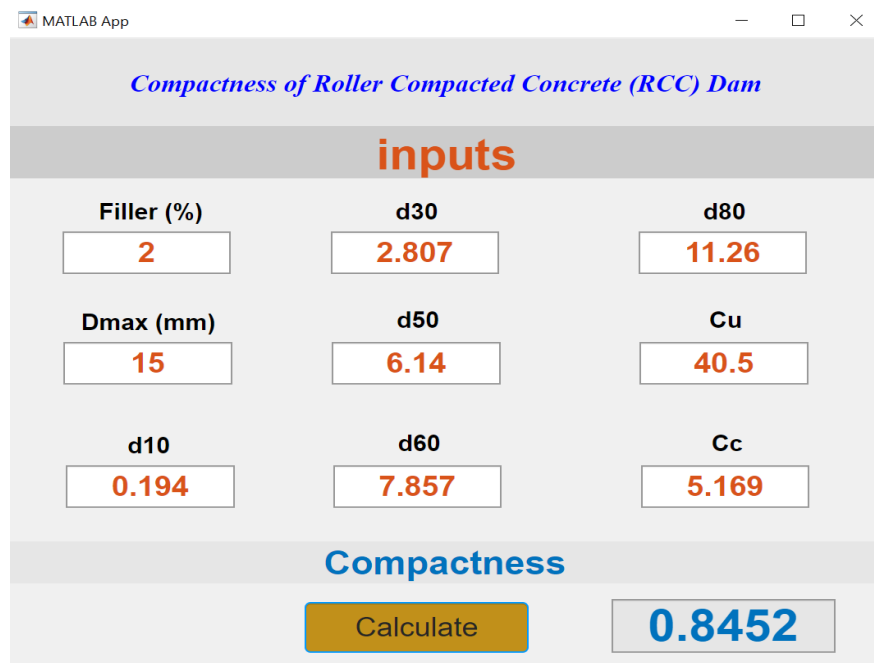


Figure V. 5 Interface utilisateur du modèle "M1" de prédiction de la compacité granulométrique

Les résultats expérimentaux et prédites de la compacité des cinq (05) mélanges granulaires pris en considération sont regroupés dans le Tableau V. 3. Ces derniers sont comparés aux compacités réelles mesurées expérimentalement. La dernière colonne du tableau qui présente

la différence en (%) entre les valeurs réelles et celles prédites par le modèle « Erreur de prédiction ». Au regard des résultats, on peut constater l'efficacité du modèle M1 développé. En effet, l'Erreur de prédiction est moyenne de 0,21 % et ne dépasse pas les 0,47%, pour les exemples traités

Tableau V. 3 résultats expérimentaux et prédites de la compacité des cinq (05) mélanges granulaires pris en considération sont regroupés dans le Tableau V. 2

Mélanges	Compacité expérimentale	Compacité prédite	Erreur de prédiction (%)
M1	0,851	0,852	0,12
M2	0,845	0,843	0,24
M3	0,840	0,842	0,24
M4	0,831	0,831	0
M5	0,847	0,851	0,47

V.3 Phase II : Prédiction de la résistance à la compression, le dosage en ciment Dc et du rapport E/C

Dans cette deuxième phase, l'objectif principale est la prédiction des paramètres essentiels du BCR à savoir : Le dosage en ciment " Dc" et le rapport Eau/Ciment en fonction des paramètres du mélange granulaire fixés dans la phase I de l'étude de formulation ainsi que d'autres paramètres souhaités du BCR lui-même, tel que le temps VeBe et la résistance à la compression à un âge donné. Dans cette phase II, cinq (05) approches ont été considérées visant toutes à définir les paramètres Dc et E/C de la formulation du BCR :

V.3.1 Approche 1 : Prédiction de la résistance à la compression "Rc" (Modèle "M2")

Cette approche, permet à l'utilisateur à prédire la résistance Rc à un âge donné (28 ou 90j) en fonction de la formulation du BCR. Ainsi, il pourra varier ces paramètres, notamment le DC et le Rapport E/C jusqu'à obtention de la résistance souhaitée.

V.3.1.1 Paramètres d'entrée

V.3.1.1.1 Paramètres du mélange granulaire

A ce stade, l'utilisateur a déjà choisi son mélange granulaire, qu'il a optimisé pour avoir une compacité optimale selon la procédure expliquée dans la phase I. Les paramètres du mélange

granulaire à savoir ; la compacité C, le D_{max} et le dosage en fillers D_f ont été retenus comme entrée.

V.3.1.1.2 Propriétés du BCR souhaitées

La base de formulation du BCR est de cibler les propriétés du mélange lui-même. Le dosage en ciment, le rapport Eau/Ciment, l'âge du BCR ainsi que la résistance vraie du ciment ont été choisis comme paramètres d'entrées. La Figure V. 6 illustre une interface utilisateur développée pour la prédiction de la résistance à compression. L'architecture de cette approche du modèle "M2" est définie dans Figure V. 7.

The screenshot shows a MATLAB App window titled "MATLAB App" with a close, maximize, and minimize button set. The main content area has a title "Compressive strength of Roller Compacted Concrete (RCC) Dam" in blue italicized font. Below the title is a section labeled "Inputs" in orange bold font. This section contains seven input fields with orange text: "Dmax (mm)" with value 50, "Filler rate (Kg/m3)" with value 125, "Compactness" with value 0.8526, "W/C ratio" with value 0.66, "Cement strength (Mpa)" with value 44, "Age (days)" with value 28, and "Cement rate (Kg/m3)" with value 140. Below the inputs is a section labeled "Compressive strength (Mpa)" in blue bold font. At the bottom, there is a yellow "Calculate" button and a grey box displaying the result "17.15" in blue bold font.

Figure V. 6 Interface utilisateur du modèle "M2" de prédiction de la résistance à la compression du BCR

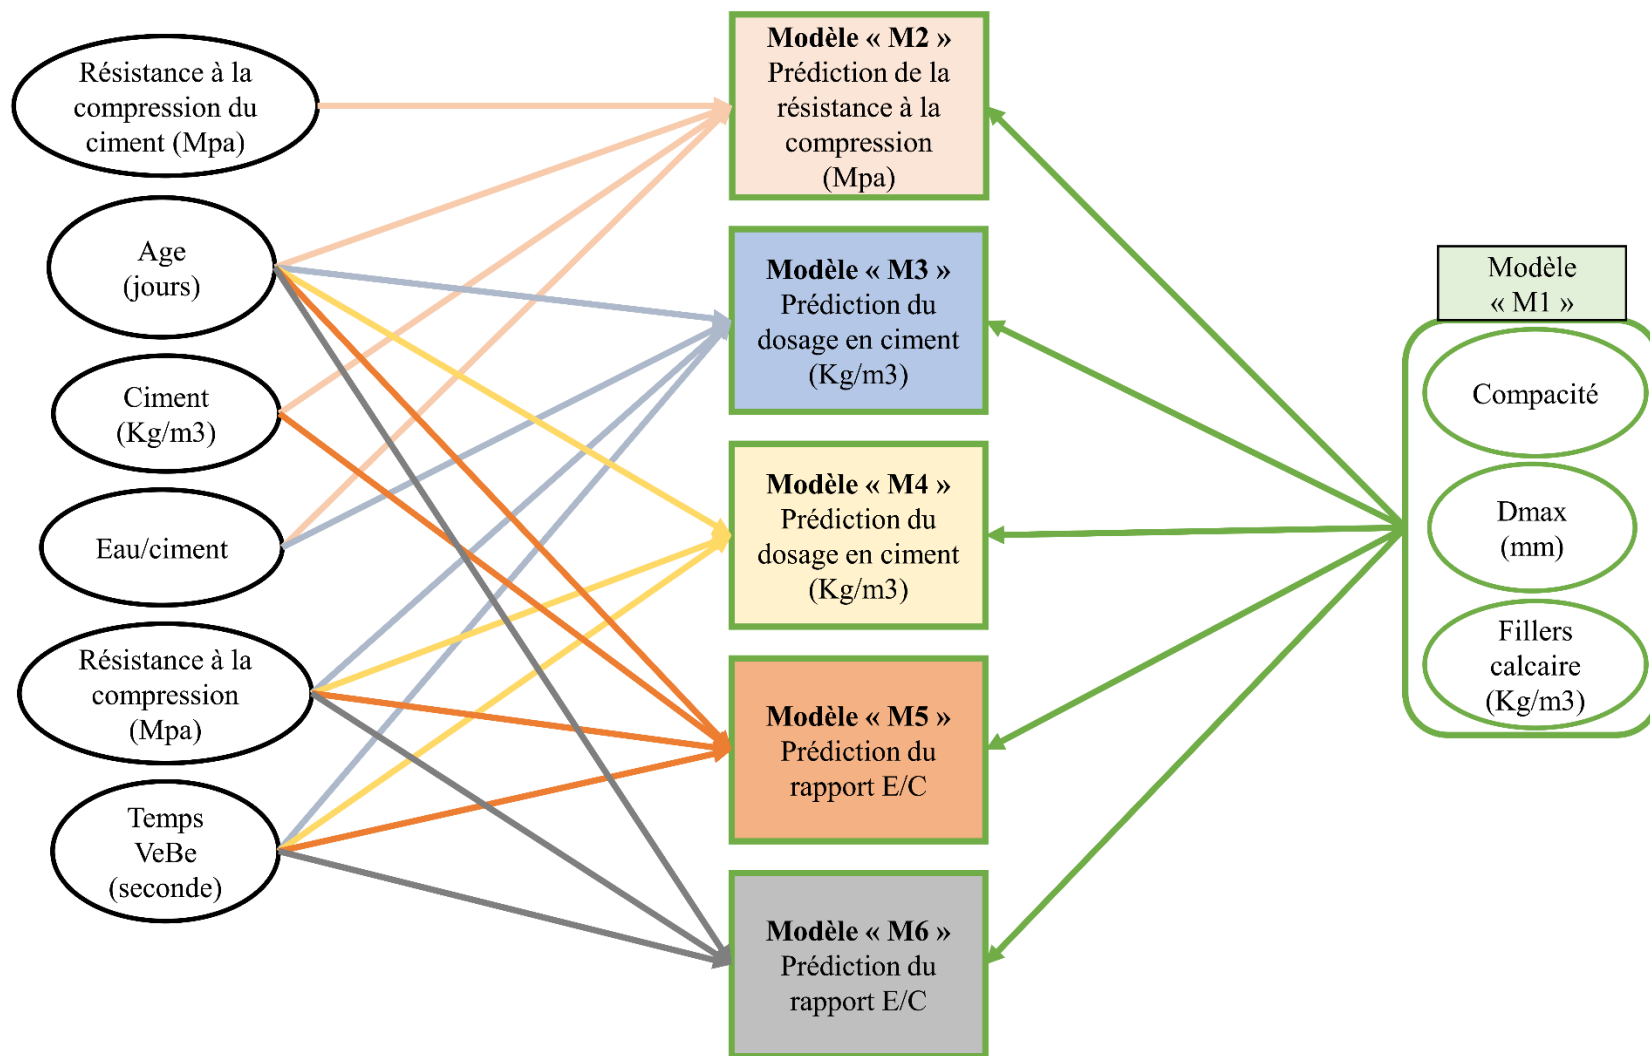


Figure V. 7 Organigramme globale de la méthodologie de prédiction des paramètres importants du BCR

V.3.1.2 Exemples de simulation

Le **Tableau V. 4** illustre cinq (05) exemples de formulation de BCR, ainsi que leurs résistances à la compression prédites par le modèle. Les cinq BCR ont été réalisés au laboratoire à partir des mélanges granulaires notés dans le **Tableau V. 1**. Pour des raisons de comparaison, les résistances obtenues expérimentalement sont présentées dans le **Tableau V. 4**. Au regard des résultats, on peut voir l'efficacité du modèle M2. On peut voir l'efficacité du modèle M2. En effet, l'Erreur de prédiction est moyenne de 7 % et ne dépasse pas les 9,88 %, pour les exemples traités.

Tableau V. 4 Exemple de simulation de la Prédiction de la résistance à la compression du BCR par le modèle M2

BCR	Paramètres d'entrées							Paramètres de sortie (Résistance à la compression)		Erreur de prédiction (%)
	Dmax (mm)	Compacité "c"	Fillers (Kg/m ³)	Age (Jours)	E/C	Dosage en ciment (Kg/m ³)	Rc ciment à 28 jours	Rc Prédite (MPa)	"Rc" expérimentale (MPa)	
1	40	0,852	140	28	0,85	130	44	14,37	15,37	6,51
2	40	0,843	150	28	0,85	150	44	17,23	17,36	0,75
3	50	0,842	140	28	0,65	115	44	10,41	11,55	9,88
4	50	0,831	150	28	0,85	150	44	13,96	15,25	8,46
5	63	0,851	145	28	0,75	130	44	12,34	13,6	9,26

V.3.2 Approche 2 : Prédiction du dosage en ciment "Dc" (modèle "M3")

Cette approche, permet à l'utilisateur à prédire le dosage en ciment Dc en fonction des propriétés du mélange granulaire et la résistance à la compression Rc souhaitée à un âge donné (28 ou 90j) la formulation du BCR.

V.3.2.1 Paramètres d'entrée

V.3.2.1.1 Paramètres du mélange granulaire

Dans cette approche, l'utilisateur a déjà défini la compacité optimale dans la phase I. Le D_{max} , le dosage en fillers ainsi que la compacité optimale ont été retenus comme entrée dans l'approche 2 de la phase II.

V.3.2.1.2 Propriétés du BCR souhaitées

Dans cette partie, dans le but de prédire le dosage en ciment "Dc", l'Age de de l'écrasement, le dosage en filler Df, ainsi que la résistance à la compression "Rc" ont été considérés comme paramètres significatifs. La **Figure V. 8** illustre une interface utilisateur développée pour la prédiction du dosage en ciment. L'architecture du modèle "M4" est définie dans la **Figure V. 7**

The screenshot shows a MATLAB App window titled "MATLAB App" with a subtitle "Cement rate of Roller Compacted Concrete (RCC) Dam". Under the heading "inputs", there are six input fields arranged in two columns. The first column contains: "Dmax (mm)" with value 50, "Compactness" with value 0.8526, and "Age (days)" with value 28. The second column contains: "Filler rate (Kg/m3)" with value 125, "VeBe time (s)" with value 22, and "Compressive strength (Mpa)" with value 18.6. Below the inputs is a large blue button labeled "Calculate". To the right of the button is a display box showing the result "141.5" in blue text, with the label "Cement rate (Kg/m3)" above it.

Figure V. 8 Interface utilisateur du modèle "M4" de prédiction du dosage en ciment du BCR

V.3.2.2 Exemples de simulation

Le Tableau V. 5 illustre les résultats de prédiction du dosage en ciment des cinq mélanges en (BCR) réalisés à partir des mélanges granulaires présentés dans le Tableau V. 1 et à partir des propriétés souhaitées. Les dosages en ciment D_c prédits des 05 BCR présentés sont confrontés aux dosages en ciment réels utilisés dans leur confection. Au vu des résultats de simulation, on peut voir l'efficacité du modèle M3. On peut voir l'efficacité du modèle M3. En effet, l'Erreur de prédiction est moyenne de 1,32 % et ne dépasse pas les 1,74 %, pour les exemples traités.

Tableau V. 5 Exemple de simulation de la Prédiction du dosage en ciment des BCR par le modèle M4

BCR	Paramètres d'entrées						Paramètres de sorties		Erreur de prédiction (%)
	Dmax (mm)	Compacité "c"	Fillers (Kg/m ³)	Age (Jours)	Résistance à la compression "Rc" expérimentale (Mpa)	VeBe (s)	Dosage en ciment prédit "Dc" (Kg/m ³)	Dosage en ciment (Kg/m ³)	
1	40	0,852	140	28	15,37	18	127,33	130	2,05
2	40	0,843	150	28	17,36	18	148,03	150	1,31
3	50	0,842	140	28	11,55	22	114,20	115	0,69
4	50	0,831	150	28	15,25	19	147,39	150	1,74
5	63	0,851	145	28	13,6	20	128,92	130	0,83

V.3.3 Approche 3 : Prédiction du dosage en ciment "Dc" en tenant compte le rapport E/C (modèle "M4")

Dans cette approche nous avons considéré les mêmes paramètres d'entrées de l'approche 2 en ajoutant le rapport E/C. Cette approche permettra à l'utilisateur de choisir son rapport E/C dans la formulation et de prédire le dosage en ciment nécessaire à l'obtention des propriétés du BCR souhaitées (Rc et Temps VeBe). La Figure V. 9 illustre une interface utilisateur développée. L'architecture de l'approche guidée par le modèle "M3" est illustrée dans la Figure V. 7

inputs					
Dmax (mm)	50	Filler rate (Kg/m3)	125		
Compactness	0.8526	W/C ratio	0.66	VeBe time (s)	22
Age (days)	28	Compressive strength (Mpa)	18.6		

Cement rate (Kg/m3)

Calculate **140.8**

Figure V. 9 Interface utilisateur du modèle "M2" de prédiction du dosage en ciment du BCR en tenant compte le rapport E/C

V.3.3.1 Exemples de simulation

Dans ce cas nous avons considéré les mêmes mélanges de BCR pris en compte dans l'approche 2. Le **Tableau V. 6** illustre les résultats de prédiction du dosage en ciment des cinq mélanges en (BCR) réalisés à partir des mélanges granulaires notés dans le **Tableau V. 1** et à partir des propriétés souhaitées. Les résultats sont confrontés aux dosages en ciment utilisés réellement pour la confection des BCR au laboratoire. On peut constater l'efficacité du modèle M4. En effet, l'Erreur de prédiction est moyenne de 1 % et ne dépasse pas les 1,56 %, pour les exemples traités

Tableau V. 6 Exemple de Prédiction du dosage en ciment des BCR en tenant compte le rapport EC (Modèle M3)

BCR	Paramètres d'entrées							Paramètres de sortie		Erreur de prédiction (%)
	Dmax (mm)	Compacité "c"	Fillers (Kg/m ³)	Age (Jours)	E/C	Résistance à la compression "Rc" expérimentale (Mpa)	VeBe (s)	Ciment prédit (Kg/m ³)	Ciment expérimentale (Kg/m ³)	
1	40	0,852	140	28	0,85	15,37	18	128,49	130	1,16
2	40	0,843	150	28	0,85	17,36	18	149,03	150	0,64
3	50	0,842	140	28	0,65	11,55	22	113,20	115	1,56
4	50	0,831	150	28	0,85	15,25	19	149,11	150	0,59
5	63	0,851	145	28	0,75	13,6	20	128,11	130	1,45

V.3.4 Approche 4 : Prédiction du rapport Eau/Ciment (modèle "M5")

Cette étape est la suite logique de l'approche 2, qui a consisté à prédire le dosage en ciment Dc. Pour cela, le Dc obtenue par l'approche 2 est introduit comme paramètre d'entrée en plus des autres paramètres d'entrées. Le rapport Eau/ciment est considéré comme paramètre de sortie. La Figure V. 10 illustre une interface utilisateur développée. L'organigramme de l'approche du modèle "M5" est présenté dans la **Figure V. 7** .Il est à noter que par cette approche, l'utilisateur a la possibilité de choisir son propre dosage en ciment Dc et de prédire le rapport E/C correspondant afin d'aboutir aux propriétés du BCR désirées.

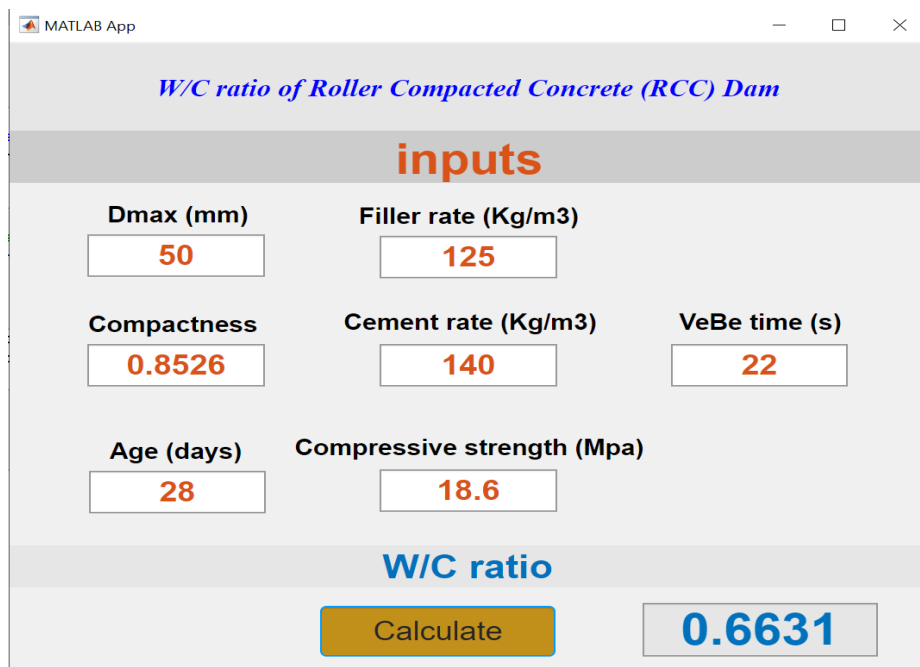


Figure V. 10 Interface utilisateur du modèle "M5" de prédiction du rapport E/C du BCR.

V.3.4.1 Exemples de simulation

Le Tableau V. 7 illustre les résultats de prédiction du dosage en ciment de cinq (05) mélanges BCR réalisés à partir des mélanges granulaires notés dans le Tableau V. 1. La dernière colonne du tableau qui présente la différence en (%) entre les valeurs réelles et celles prédites par le modèle « Erreur de prédiction ». Au regard des résultats, on peut constater l'efficacité du modèle M5 développé. En effet, l'Erreur de prédiction est moyenne de 5% et ne dépasse pas les 7,06%, pour les exemples traités.

Tableau V. 7 Exemple de simulation du rapport E/C du BCR à partir de mélange granulaire optimisé et des propriétés souhaitées, par le modèle M5

BCR	Paramètres d'entrées							Paramètres de sortie		Erreur de prédiction (%)
	Dmax (mm)	Compacité "c"	Fillers (Kg/m ³)	Age (Jour s)	Dosage en ciment (Kg/m ³)	Résistance "Rc" Souhaitée (MPa)	VeBe (s)	E/C prédit	E/C expérimental	
1	40	0,852	140	28	130	15,37	18	0,79	0,85	7,06
2	40	0,843	150	28	150	17,36	18	0,81	0,85	4,71
3	50	0,842	140	28	115	11,55	22	0,68	0,65	4,62
4	50	0,831	150	28	150	15,25	19	0,82	0,85	3,53
5	63	0,851	145	28	130	13,6	20	0,79	0,75	5,33

V.3.5 Approche 5 : Prédiction du dosage en ciment "Dc" et du rapport "E/C" simultanément (Modèle M6)

Pour cette approche, l'utilisateur détermine en phase I les paramètres du mélange granulaire choisi et passe par le modèle "M6" pour prédire un couple de (Dc et E/C) correspondant aux paramètres du BCR souhaités (Rc, temps VeBe, Age). Pour ce faire, une interface utilisateur a été développée (Figure V. 11). L'architecture de l'approche (modèle "M6") est présentée dans la Figure V. 7

W/C ratio and cement rate of Roller Compacted Concrete (RCC) Dam

inputs

Dmax (mm)	40	Filler rate (Kg/m3)	140
Compactness	0.843	Compressive strength (Mpa)	15.37
Age (days)	28	VeBe time (s)	18
Cement rate (Kg/m3)		W/C ratio	
127.4		0.81	

Calculate

Figure V. 11 Interface utilisateur du modèle "M6" de prédiction de "Dc" et "E/C" simultanément

V.3.5.1 Exemples de simulation

Dans ce cas, en plus des paramètres granulométriques déjà définis (Compacité, dosage en fillers et le D_{max}), l'utilisateur doit ajouter les propriétés du BCR souhaitées à savoir l'âge, le temps de VeBe et la résistance à la compression R_c pour prédire le dosage en ciment D_c et le rapport E/C. Le Tableau V. 8 illustre les résultats de prédiction du dosage en ciment et du rapport E/C des cinq mélanges en (BCR) réalisés à partir des mélanges granulaires notés dans le Tableau V. 1 et à partir des propriétés souhaitées. La dernière colonne du tableau qui présente la différence en (%) entre les valeurs réelles et celles prédites par le modèle « Erreur de prédiction ». On peut constater l'efficacité du modèle M6. En effet, l'Erreur de prédiction du C et de E/C est moyenne de 4 % et 1,6 % respectivement, et ne dépasse pas les 6,15 % et pour le dosage en ciment et 3,06 % pour le E/C

Tableau V. 8 Exemple de simulation du rapport E/C et du dosage en ciment "Dc" du BCR à partir de mélange granulaire optimisé et des propriétés souhaités (Modèle M6)

BCR	Paramètres d'entrées						Paramètres de sortie				Erreur de prédiction (%)	
	Dmax (mm)	Compacité "c"	Fillers (Kg/m ³)	Age (Jours)	Résistance à la compression "Rc" expérimentale (Mpa)	VeBe (s)	E/C prédit	E/C expérimentale	Dosage en ciment prédit "Dc" (Kg/m ³)	Dosage en ciment "Dc" (Kg/m ³)	"Dc"	"E/C"
1	40	0,852	140	28	15,37	18	0,81	0,85	127,43	130	4,70	1,97
2	40	0,843	150	28	17,36	18	0,83	0,85	148,86	150	2,35	0,76
3	50	0,842	140	28	11,55	22	0,61	0,65	111,48	115	6,15	3,06
4	50	0,831	150	28	15,25	19	0,87	0,85	149,10	150	2,35	0,6
5	63	0,851	145	28	13,6	20	0,72	0,75	132,48	130	4	1,91

V.4 Conclusion

Dans ce volet de l'étude, une méthodologie globale de la formulation du BCR a été présentée. La première étape « phase I » a été consacrée sur l'optimisation du squelette granulaire à partir des courbes granulométriques des mélanges. La deuxième phase a été réservée pour la prédiction des paramètres importants du BCR à partir des propriétés du BCR désirées et des propriétés du mélange granulaire issu de la phase I. Un organigramme général des modèles développés a été présenté à la fin et pour chaque paramètre prédit, une interface utilisateur a été développée pour faciliter la manipulation des modèles de prédiction développés. Pour chaque étape de formulation, les résultats des cinq exemples de simulation proposés, ont montré une bonne efficacité de la méthodologie proposée pour la formulation des BCR pour barrage. Les erreurs de prédiction des différents modèles, ne dépassant pas les 10 %, sont considérées comme acceptables.

La synthèse bibliographique sur les différents matériaux du BCR et ses propriétés à l'état frais et durci, ainsi que sur les méthodes d'optimisation intelligentes, a permis de retenir les observations suivantes :

- Par rapport au béton conventionnel, le BCR est défini par l'utilisation des fins (filler) <1mm ainsi que l'utilisation des ballasts de gros diamètre, dépassant les 40 mm, dans le but de remplir les vides intergranulaires et atteindre une compacité maximale.
- Le BCR est spécifié par l'utilisation d'un faible dosage du ciment dans le but d'éviter les fissurations dues au dégagement de chaleur lors de l'hydratation du ciment ainsi que pour minimiser le coût de la construction.
- L'ouvrabilité du BCR est appréciée par le temps VeBe, qui est un paramètre de premier ordre dans la formulation du BCR. CE dernier est conditionné par la compacité du mélange granulaire ainsi que le volume de la pâte de liant.
- A l'état durci, principalement, la résistance mécanique est considérée comme propriétés essentielle du BCR. Cette dernière est influencée directement par les paramètres de sa formulation, tel que le Dosage en ciment, le rapport E/C, le type et dosage en fillers et la compacité du mélange granulaire.
- Les méthodes de formulation actuelles du BCR sont regroupées en trois grandes catégories : Empiriques, semi-empiriques et théoriques. Ces dernières, même si elles donnent de bons résultats, sont généralement basées sur les expérimentations lourdes et contraignantes.
- Les techniques d'intelligence artificielle tel que les réseaux de neurones RNA et les algorithmes d'essaims de particules (PSO) ont été souvent utilisées pour la prévision des propriétés des bétons avec succès. Ces méthodes sont considérées comme un outil utile et puissant pour la résolution de problème d'optimisation complexes, en comparaison avec les méthodes statistiques et mathématiques conventionnelles.

Le troisième chapitre de la recherche a concerné l'optimisation du squelette granulaire du BCR par un système intelligent à base de RNA en fonction des paramètres géométriques, tirés d'une modélisation de la courbe granulométrique du mélange. De cette étude, les appréciations suivantes sont avancées :

Conclusions générales

- L'essai de mesure de la compacité développé et optimisé au laboratoire, a permis la mesure de la compacité des 176 mélanges granulaires BCR étudiés. La base de données constituée avec ses larges intervalles de variations, a permis un bon apprentissage des modèles développés. et leurs offrent plus de crédibilité.
- L'hybridation du RNA par des PSO a montré son efficacité par rapport au modèle RNA optimisé par l'algorithme de Levenberg-Marquardt.
- Par rapport au modèle RNA, le modèle RNA-PSO a montré une très bonne capacité de prédiction de la compacité granulaire des mélanges de BCR expérimentés avec un facteur de corrélation significatif ($R = 0,93$) et de bonnes valeurs des indicateurs statistiques (une Erreur quadratique (MSE) avec l'Erreur quadratique moyenne (RMSE) égale à $2,72e^{-05}$ et 0,0052 respectivement, l'Erreur absolue moyenne (MAE) de 0,0042 avec une Erreur moyenne absolue en pourcentage (MAPE) de 0,5030 %).
- L'étude de sensibilité du modèle RNA-PSO a montré un comportement habituel de la compacité en fonction de paramètres essentiels de variation, tel que le D_{max} et le taux de fines dans les mélanges granulaires. Cette tendance correspond largement avec la littérature.
- Enfin, on peut constater que le modèle de prédiction de la compacité développé, s'appuyant sur des paramètres géométriques simplement mesurables, constitue un outil de prédiction efficace pour des mélanges rentrant dans les fuseaux granulaires étudiés, qui couvrent un domaine d'utilisation très large dans la conception des bétons compactés au rouleau « BCR ».

De l'étude d'optimisation des propriétés essentielles de la formulation du BCR, les conclusions suivantes peuvent être tirées :

- Les systèmes de prédiction intelligent RNA et RNA-PSO développés ont montré l'efficacité des métaheuristiques dans la prédiction des paramètres importants du BCR de barrage. Le développement des modèles de prédiction a été basé sur 500 vecteurs ayant un large intervalle de variation des différents paramètres de formulation (entrée) et de la résistance (sortie).
- Les modèles ont été validés expérimentalement au laboratoire et comparés avec la méthode LCPC. Même, avec les légères différences dans les matériaux et du mode de mise en œuvre du béton, les systèmes développés RNA et RNA-PSO ont montré de très

bonnes capacités de prédiction de la résistance à la compression, le dosage en ciment D_c ainsi que le rapport E/C des BCR expérimentés. Les résultats obtenus par la méthode LCPC restent peu précises avec de faibles corrélations.

Enfin, en se basant sur les différents modèles d'optimisation des paramètres du BCR et de ses substituants (Compacité du mélange, dosage en ciment, rapport E/C), en fonction des matériaux utilisés et des propriétés souhaitées, une méthode globale de formulation a été développée. La méthode a été valorisée par des interfaces visuelles, réalisée à l'aide du Matlab pour offrir à l'utilisateur une facilité et une attractivité d'exploitation.

Recommandations

L'étude conduite dans le cadre de notre recherche nous a permis de dégager une méthodologie de formulation des BCR pour barrage s'appuyant sur l'expérience de la réalisation de plusieurs barrages en BCR et sur les techniques d'optimisation intelligentes. Cependant, ce travail reste considéré comme une bonne contribution et devrait être complété par les suggestions suivantes :

- L'élargissement de la base de données avec d'autres formulations de BCR, contenant d'autres types d'ajouts actifs tel que le laitier de haut fourneau ou les cendres volantes. Ceci permettra d'inclure d'autres paramètres d'entrée dans les modèles de formulation développés.
- L'hybridation des RNA avec d'autres métaheuristiques telles que l'algorithme du loup gris (GWO), Algorithme de colonies de fourmis (ACO), l'algorithme génétique (GA)...etc.
- Intégrer d'autres paramètres du BCR tel que les propriétés de transfert thermique et d'étanchéité du béton (porosité et perméabilité).
- Enfin il serait souhaitable de développer une interface utilisateur globale pour la prédiction des paramètres importants pour différents types de béton à l'aide des techniques issues de l'intelligence artificielle.

Références bibliographiques

- [1] ACI Committee 207, Roller-Compacted Mass Concrete, American Concrete Institute, U.S.A, 1999.
- [2] R. Gagné, Méthodes de formulation et d'optimisation des mélanges de BCR, 51.
- [3] de Larrard F, Sedran T (2009) Le logiciel BétonlabPro 3: Bulletin des Laboratoires des Ponts et Chaussées
- [4] M. Parizeau, RÉSEAUX DE NEURONES, Québec, 2004.
- [5] pierre Borne, M. Benrajeb, J. Haggège, Les réseaux de neurones présentation et applications, Technip, PARIS, 2007.
- [6] H. Cartwright, ed., Artificial Neural Networks, Springer US, New York, NY, 2021. <https://doi.org/10.1007/978-1-0716-0826-5>.
- [7] I.-C. Yeh, Exploring Concrete Slump Model Using Artificial Neural Networks, Journal of Computing in Civil Engineering. 20 (2006) 217–221. [https://doi.org/10.1061/\(ASCE\)0887-3801\(2006\)20:3\(217\)](https://doi.org/10.1061/(ASCE)0887-3801(2006)20:3(217)).
- [8] J. Bai, S. Wild, J.A. Ware, B.B. Sabir, Using neural networks to predict workability of concrete incorporating metakaolin and fly ash, Advances in Engineering Software. 34 (2003) 663–669. [https://doi.org/10.1016/S0965-9978\(03\)00102-9](https://doi.org/10.1016/S0965-9978(03)00102-9).
- [9] A. Hammoudi, K. Moussaceb, C. Belebchouche, F. Dahmoune, Comparison of artificial neural network (ANN) and response surface methodology (RSM) prediction in compressive strength of recycled concrete aggregates, Construction and Building Materials. 209 (2019) 425–436. <https://doi.org/10.1016/j.conbuildmat.2019.03.119>.
- [10] A.T. Amlashi, S.M. Abdollahi, S. Goodarzi, A.R. Ghanizadeh, Soft computing based formulations for slump, compressive strength, and elastic modulus of bentonite plastic concrete, Journal of Cleaner Production. 230 (2019) 1197–1216. <https://doi.org/10.1016/j.jclepro.2019.05.168>.
- [11] K.-B. Park, T. Noguchi, J. Plawsky, Modeling of hydration reactions using neural networks to predict the average properties of cement paste, Cement and Concrete Research. 35 (2005) 1676–1684. <https://doi.org/10.1016/j.cemconres.2004.08.004>.
- [12] D. Harrington, F. Abdo, W. Adaska, C. Hazaree, Guide for Roller-Compacted Concrete Pavements, Institute for Transportation, Iowa State University. (2010) 104.
- [13] ACI Committee 207, American Concrete Institute, Report on roller-compacted mass concrete, American Concrete Institute, Farmington Hills, MI, 2011.
- [14] Icold Committee on Concrete Dams: Roller-Compacted Concrete Dams, CRC Press, 2020. <https://doi.org/10.1201/9780429329012>.
- [15] C. Chhorn, S.J. Hong, S.W. Lee, Relationship between compressive and tensile strengths of roller-compacted concrete, Journal of Traffic and Transportation Engineering (English Edition). 5 (2018) 215–223. <https://doi.org/10.1016/j.jtte.2017.09.002>.
- [16] ACI Committee 209.2R-08, American Concrete Institute, Farmington Hills, MI, 2008.
- [17] Frost Durability of Roller-Compacted Concrete Pavements, (n.d.) 150.
- [18] Roller Compacted Concrete Dams | Taylor & Francis Group, Taylor & Francis.. <https://www.taylorfrancis.com/https://www.taylorfrancis.com/books/edit/10.1201/9780203741276/roller-compacted-concrete-dams-berga-buil-jofré-chonggang> (accessed April 2, 2021).
- [19] Official Publications of the Headquarters, U.S. Army Corps of Engineers, Roller-Compacted Concrete, (2000).
- [20] Projet National BaCaRa, Le béton compacté au rouleau: les barrages en BCR, Presses de l'École Nationale des Ponts et Chaussées, Paris, 1996.
- [21] V.E. Fedosov, E.A. Kogan, A.D. Osipov, Materials for roller compacted concrete used in modern dam construction, Hydrotechnical Construction. 32 (1998) 181–188. <https://doi.org/10.1007/BF02918723>.
- [22] L. André, M. Jean-Michel, Compacité des mélanges et propriétés des grains, (1999) 21–33.
- [23] S. Kitouni, H. Houari, Lightweight concrete with Algerian limestone dust: Part I: Study on 30% replacement to normal aggregate at early age, Cerâmica. 59 (2013) 600–608. <https://doi.org/10.1590/S0366-69132013000400017>.

Références bibliographiques

- [24] S. El Euch Khay, T. Achour, A. Bouslah, J. Neji, Characterization and Modeling of Tensile Strength of High-Limestone Filler Concretes for Pavement, *J. Mater. Civ. Eng.* 30 (2018) 04018223. [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0002439](https://doi.org/10.1061/(ASCE)MT.1943-5533.0002439).
- [25] S.A. Yildizel, G. Calis, B.A. Tayeh, Mechanical and durability properties of ground calcium carbonate-added roller-compacted concrete for pavement, *Journal of Materials Research and Technology.* 9 (2020) 13341–13351. <https://doi.org/10.1016/j.jmrt.2020.09.070>.
- [26] A. Hadj-sadok, S. Kenai, L. Courard, A. Darimont, Microstructure and durability of mortars modified with medium active blast furnace slag, *Construction and Building Materials.* 25 (2011) 1018–1025. <https://doi.org/10.1016/j.conbuildmat.2010.06.077>.
- [27] V.C. Pandey, Fly ash properties, multiple uses, threats, and management: an introduction, in: *Phytomanagement of Fly Ash*, Elsevier, 2020: pp. 1–34. <https://doi.org/10.1016/B978-0-12-818544-5.00001-8>.
- [28] Gautier P, Marchand J (2017) Conception et réalisation de revêtement de BCR au Québec
- [29] M. Pigeon, R. Pleau, Durability of Concrete in Cold Climates., 2011. <http://public.ebookcentral.proquest.com/choice/publicfullrecord.aspx?p=487999> (accessed November 4, 2020).
- [30] M. Zdiri, M. Ben Ouedzou, J. Neji, Theoretical and experimental study of roller-compacted concrete strength, *Magazine of Concrete Research.* 60 (2008) 469–474. <https://doi.org/10.1680/mac.2007.00002>.
- [31] Berga et al. - 2003 - Roller compacted concrete dams proceedings of the.pdf, (n.d.).
- [32] F. de Larrard, *Concrete mixture proportioning: a scientific approach*, E & FN Spon, London, 1999.
- [33] E. Rahmani, M.Kazem. Sharbatdar, M. H.A.Beygi, A comprehensive investigation into the effect of water to cement ratios and cement contents on the physical and mechanical properties of Roller Compacted Concrete Pavement (RCCP), *Construction and Building Materials.* 253 (2020) 119177. <https://doi.org/10.1016/j.conbuildmat.2020.119177>.
- [34] P.D. Tennis, M.L. Leming, D.J. Akers, *Pervious Concrete Pavements*, (n.d.) 32.
- [35] Mohd. Ahmed, J. Mallick, Mohd. Abul Hasan, A study of factors affecting the flexural tensile strength of concrete, *Journal of King Saud University - Engineering Sciences.* 28 (2016) 147–156. <https://doi.org/10.1016/j.jksues.2014.04.001>.
- [36] J. Kalla, S. Karri, K.V. Sathi, Experimental analysis on modulus of elasticity of slag based concrete, *Materials Today: Proceedings.* (2020). <https://doi.org/10.1016/j.matpr.2020.07.537>.
- [37] B. Bissonnette, M. Pigeon, Le comportement viscoélastique du béton en traction et la compatibilité déformationnelle des réparations, (2000) 108–111.
- [38] M.G. Assaf, Développement d'un catalogue de dimensionnement structural des chaussées pour la ville de Montréal, (n.d.) 223.
- [39] C. Hazaree, H. Ceylan, K. Wang, Influences of mixture composition on properties and freeze–thaw resistance of RCC, *Construction and Building Materials.* 25 (2011) 313–319. <https://doi.org/10.1016/j.conbuildmat.2010.06.023>.
- [40] M. Broucek, L. Satrapa, Recent enhancement of the RCC technology in dam engineering, in: *Lisek, Czech Republic*, 2020: p. 020003. <https://doi.org/10.1063/5.0000378>.
- [41] 309.5R-00 Compaction of Roller-Compacted Concrete, (n.d.) 15.
- [42] M.R.H. Dunstan, THE DEVELOPMENT OP HIGH PLYASH CONTENT CONCRETE (Volume I - Script and Appendices), (n.d.) 406.
- [43] M.I. Abu-Khashaba, I. Adam, A. El-Ashaal, Investigating the possibility of constructing low cost roller compacted concrete dam, *Alexandria Engineering Journal.* 53 (2014) 131–142. <https://doi.org/10.1016/j.aej.2013.11.009>.
- [44] G. Calis, S.A. Yildizel, Investigation of roller compacted concrete: Literature review, *Challenge Journal of Concrete Research Letters.* 10 (2019) 63. <https://doi.org/10.20528/cjcr.2019.03.003>.
- [45] ACI Committee 211 - ACI 211.3R-02_ Guide for Selecting Proportions for No-Slump Concrete (Reapproved 2009)-American Concrete Institute (ACI) (2002).

Références bibliographiques

- [46] ACI Committee 209.2R-08, Guide for Modeling and Calculating Shrinkage and Creep in Hardened Concrete, American Concrete Institute, Farmington Hills, 2008.
- [47] ACI Committee 207 (1999) Roller-compacted mass concrete. ACI 207.5R- 99, American Concrete Institute, Farmington Hills, MI, USA
- [48] R. Gagné, High-performance roller-compacted concrete for pavement - Mixture design, (2000) 74–88.
- [49] T. Stovall, F. de Larrard, M. Buil, Linear packing density model of grain mixtures, Powder Technology. 48 (1986) 1–12. [https://doi.org/10.1016/0032-5910\(86\)80058-4](https://doi.org/10.1016/0032-5910(86)80058-4).
- [50] Y. Cherait, Contribution à l'étude des empilements granulaires-Approche théorique et expérimentale, Guelma, 2005.
- [51] M. Abdallah, M. Abu Talib, S. Feroz, Q. Nasir, H. Abdalla, B. Mahfood, Artificial intelligence applications in solid waste management: A systematic research review, Waste Management. 109 (2020) 231–246. <https://doi.org/10.1016/j.wasman.2020.04.057>.
- [52] K. Yetilmezsoy, B. Ozkaya, M. Cakmakci, ARTIFICIAL INTELLIGENCE-BASED PREDICTION MODELS FOR ENVIRONMENTAL ENGINEERING, Neural Network World. 21 (2011) 193–218. <https://doi.org/10.14311/NNW.2011.21.012>.
- [53] A. Konar, Artificial intelligence and soft computing: behavioral and cognitive modeling of the human brain, CRC Press, Boca Raton, Fla., 2000.
- [54] John H. Holland - Adaptation in Natural and Artificial Systems_ An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence-The MIT Press (1992).pdf, (n.d.).
- [55] B. Boukhatem, R. Rebouh, A. Zidol, M. Chekired, A. Tagnit-Hamou, An intelligent hybrid system for predicting the tortuosity of the pore system of fly ash concrete, Construction and Building Materials. 205 (2019) 274–284. <https://doi.org/10.1016/j.conbuildmat.2019.02.005>.
- [56] C. Youcef, H.S. Ahmed, Conférence Internationale Francophone NoMaD 2018 Optimisation des paramètres essentiels de la formulation d'un BCR à base de fillers calcaire par les réseaux de neurones artificiels « RNA », (2018).
- [57] Shanmuganathan et Samarasinghe - 2016 - Artificial Neural Network Modelling.pdf, (n.d.).
- [58] J. Vesanto, SOM-based data visualization methods, Intelligent Data Analysis. (1999) 16.
- [59] R. Chauhan, H. Kaur, M.A. Alam, Data Clustering Method for Discovering Clusters in Spatial Cancer Databases, International Journal of Computer Applications. 10 (2010) 9–14. <https://doi.org/10.5120/1487-2004>.
- [60] T. Ji, T. Lin, X. Lin, A concrete mix proportion design algorithm based on artificial neural networks, Cement and Concrete Research. 36 (2006) 1399–1408. <https://doi.org/10.1016/j.cemconres.2006.01.009>.
- [61] S. Ghosh-Dastidar, H. Adeli, SPIKING NEURAL NETWORKS, (2009) 14.
- [62] G. Bebis, M. Georgiopoulos, Feed-forward neural networks, 13 (1994). <https://doi.org/10.1109/45.329294>.
- [63] G. Dorffner, ICANN, eds., Artificial neural networks: international conference, Vienna, Austria, August 21 - 25, 2001 ; proceedings, Springer, Berlin, 2001.
- [64] J. Park, I.W. Sandberg, Universal Approximation Using Radial-Basis-Function Networks, Neural Computation. 3 (1991) 246–257. <https://doi.org/10.1162/neco.1991.3.2.246>.
- [65] M. Ishikawa, K. Doya, H. Miyamoto, T. Yamakawa, eds., Neural Information Processing: 14th International Conference, ICONIP 2007, Kitakyushu, Japan, November 13-16, 2007, Revised Selected Papers, Part II, Springer Berlin Heidelberg, Berlin, Heidelberg, 2008. <https://doi.org/10.1007/978-3-540-69162-4>.
- [66] K. KOUZI, Contribution des techniques de la logique floue pour la commande d'une machine à induction sans transducteur rotatif, Laghouat, 2008.
- [67] H. Simon, Neural Networks_ A Comprehensive Foundation, 2nd ed., Prentice Hall, Canada, 1998.
- [68] G. Dreyfus, Apprentissage statistique, 2008.
- [69] W. McCulloch, W. Pitts, A logical calculus of the ideas immanent in nervous activity, The Bulletin of Mathematical Biophysics. (1943) 116–133.

Références bibliographiques

- [70] S.S. Haykin, *Neural networks and learning machines*, 3. ed, Pearson, New York, 2009.
- [71] E.F. Felix, R. Carrazedo, E. Possan, Carbonation model for fly ash concrete based on artificial neural network: Development and parametric analysis, *Construction and Building Materials*. 266 (2021) 121050. <https://doi.org/10.1016/j.conbuildmat.2020.121050>.
- [72] B. Boukhatem, S. Kenai, M. Ghrici, Prédiction de l'efficacité des cendres volantes dans le béton par l'utilisation d'un réseau de neurones artificiel, (2010) 499–508.
- [73] Y. Freund, R.E. Schapire, Large margin classification using the perceptron algorithm, in: *Proceedings of the Eleventh Annual Conference on Computational Learning Theory - COLT' 98*, ACM Press, Madison, Wisconsin, United States, 1998: pp. 209–217. <https://doi.org/10.1145/279943.279985>.
- [74] H. Cartwright, ed., *Artificial Neural Networks*, Springer New York, New York, NY, 2015. <https://doi.org/10.1007/978-1-4939-2239-0>.
- [75] J. Bromley, I. Guyon, Y. LeCun, E. Säckinger, R. Shah, Signature Verification using a “Siamese” Time Delay Neural Network, (n.d.) 8.
- [76] G. Dreyfus, *Apprentissage statistique*, 2008.
- [77] M. Mordjaoui, *Modélisation des effets électromagnétiques « Apport de la logique floue et neuro-floue »*, Skikda, 2008.
- [78] D.-S. Yang, S.-K. Park, J.-H. Lee, A prediction on mix proportion factor and strength of concrete using neural network, *KSCE J Civ Eng*. 7 (2003) 525–536. <https://doi.org/10.1007/BF02838318>.
- [79] R. REBOUH, *Elaboration d'un logiciel de formulation des bétons contenant des ajouts cimentaires*, Hassiba Benbouali de Chlef, 2018.
- [80] H. Ponce-Espinosa, P. Ponce-Cruz, A. Molina, *Artificial Organic Networks: Artificial Intelligence Based on Carbon Networks*, Springer International Publishing, Cham, 2014. <https://doi.org/10.1007/978-3-319-02472-1>.
- [81] D.E. Goldberg, *Genetic Algorithms in Search, Optimization, and Machine Learning*, États-Unis, 1989.
- [82] S. Kirkpatrick, C.D. Gelatt, M.P. Vecchi, Optimization by simulated annealing, 220 (1983) 671–680. <https://doi.org/10.1126/science.220.4598.671>.
- [83] M. Dorigo, V. Maniezzo, A. Coloni, Ant system: optimization by a colony of cooperating agents, *IEEE Trans. Syst., Man, Cybern. B*. 26 (1996) 29–41. <https://doi.org/10.1109/3477.484436>.
- [84] J. Kennedy, R.C. Eberhart, A discrete binary version of the particle swarm algorithm, in: *1997 IEEE International Conference on Systems, Man, and Cybernetics. Computational Cybernetics and Simulation*, IEEE, Orlando, FL, USA, 1997: pp. 4104–4108. <https://doi.org/10.1109/ICSMC.1997.637339>.
- [85] W. Geem, *A New Heuristic Optimization Algorithm: Harmony Search*, (n.d.) 9.
- [86] A.H. Gandomi, A.H. Alavi, Krill herd: A new bio-inspired optimization algorithm, *Communications in Nonlinear Science and Numerical Simulation*. 17 (2012) 4831–4845. <https://doi.org/10.1016/j.cnsns.2012.05.010>.
- [87] X.-S. Yang, S. Koziel, eds., *Computational Optimization and Applications in Engineering and Industry*, Springer Berlin Heidelberg, Berlin, Heidelberg, 2011. <https://doi.org/10.1007/978-3-642-20986-4>.
- [88] J. Kennedy, R.C. Eberhart, Y. Shi, *Swarm intelligence*, Kaufmann, San Francisco, 2001.
- [89] R. Eberhart, Y. Shi, *Computational Intelligence Pc Tools [Books in Brief]*, 8 (2005) 817–817. <https://doi.org/10.1109/tnn.1997.572124>.
- [90] P. Krajcevski, J. Reppy, A Declarative API for Particle Systems, in: R. Rocha, J. Launchbury (Eds.), *Practical Aspects of Declarative Languages*, Springer Berlin Heidelberg, Berlin, Heidelberg, 2011: pp. 130–144. https://doi.org/10.1007/978-3-642-18378-2_12.
- [91] Y. Shi, R. Eberhart, A modified particle swarm optimizer, in: *1998 IEEE International Conference on Evolutionary Computation Proceedings. IEEE World Congress on Computational Intelligence (Cat. No.98TH8360)*, IEEE, Anchorage, AK, USA, 1998: pp. 69–73. <https://doi.org/10.1109/ICEC.1998.699146>.

Références bibliographiques

- [92] A. Abraham, H. Guo, H. Liu, Swarm Intelligence: Foundations, Perspectives and Applications, in: N. Nedjah, L. de M. Mourelle (Eds.), *Swarm Intelligent Systems*, Springer, Berlin, Heidelberg, 2006: pp. 3–25. https://doi.org/10.1007/978-3-540-33869-7_1.
- [93] M.R. Alrashidi, M.E. El-Hawary, A Survey of Particle Swarm Optimization Applications in Power System Operations, *Electric Power Components and Systems*. 34 (2006) 1349–1357. <https://doi.org/10.1080/15325000600748871>.
- [94] D. Teodorović, Swarm intelligence systems for transportation engineering: Principles and applications, *Transportation Research Part C: Emerging Technologies*. 16 (2008) 651–667. <https://doi.org/10.1016/j.trc.2008.03.002>.
- [95] D.H. Wolpert, W.G. Macready, No free lunch theorems for optimization, *IEEE Transactions on Evolutionary Computation*. 1 (1997) 67–82. <https://doi.org/10.1109/4235.585893>.
- [96] R. Rebouh, B. Boukhatem, M. Ghrici, A. Tagnit-Hamou, A practical hybrid NNGA system for predicting the compressive strength of concrete containing natural pozzolan using an evolutionary structure, *Construction and Building Materials*. 149 (2017) 778–789. <https://doi.org/10.1016/j.conbuildmat.2017.05.165>.
- [97] J.-S. Chou, C.-F. Tsai, A.-D. Pham, Y.-H. Lu, Machine learning in concrete strength simulations: Multi-nation data analytics, *Construction and Building Materials*. 73 (2014) 771–780. <https://doi.org/10.1016/j.conbuildmat.2014.09.054>.
- [98] Z. Yuan, L.-N. Wang, X. Ji, Prediction of concrete compressive strength: Research on hybrid models genetic based algorithms and ANFIS, *Advances in Engineering Software*. 67 (2014) 156–163. <https://doi.org/10.1016/j.advengsoft.2013.09.004>.
- [99] S. Popovics, J. Ujhelyi, Contribution to the Concrete Strength versus Water-Cement Ratio Relationship, *Journal of Materials in Civil Engineering*. 20 (2008) 459–463. [https://doi.org/10.1061/\(ASCE\)0899-1561\(2008\)20:7\(459\)](https://doi.org/10.1061/(ASCE)0899-1561(2008)20:7(459)).
- [100] E. Slater, M. Moni, M.S. Alam, Predicting the shear strength of steel fiber reinforced concrete beams, *Construction and Building Materials*. 26 (2012) 423–436. <https://doi.org/10.1016/j.conbuildmat.2011.06.042>.
- [101] Y.-K. Kwak, M.O. Eberhard, W.-S. Kim, J. Kim, Shear Strength of Steel Fiber-Reinforced Concrete Beams without Stirrups, *SJ*. 99 (2002) 530–538. <https://doi.org/10.14359/12122>.
- [102] A. Gholampour, A.H. Gandomi, T. Ozbakkaloglu, New formulations for mechanical properties of recycled aggregate concrete using gene expression programming, *Construction and Building Materials*. 130 (2017) 122–145. <https://doi.org/10.1016/j.conbuildmat.2016.10.114>.
- [103] R.V. Silva, J. de Brito, R.K. Dhir, Tensile strength behaviour of recycled aggregate concrete, *Construction and Building Materials*. 83 (2015) 108–118. <https://doi.org/10.1016/j.conbuildmat.2015.03.034>.
- [104] J. Namyong, Y. Sangchun, C. Hongbum, Prediction of Compressive Strength of In-Situ Concrete Based on Mixture Proportions, *Journal of Asian Architecture and Building Engineering*. 3 (2004) 9–16. <https://doi.org/10.3130/jaabe.3.9>.
- [105] M.H. Fazel Zarandi, I.B. Türksen, J. Sobhani, A.A. Ramezani pour, Fuzzy polynomial neural networks for approximation of the compressive strength of concrete, *Applied Soft Computing*. 8 (2008) 488–498. <https://doi.org/10.1016/j.asoc.2007.02.010>.
- [106] Z.M. Yaseen, R.C. Deo, A. Hilal, A.M. Abd, L.C. Bueno, S. Salcedo-Sanz, M.L. Nehdi, Predicting compressive strength of lightweight foamed concrete using extreme learning machine model, *Advances in Engineering Software*. 115 (2018) 112–125. <https://doi.org/10.1016/j.advengsoft.2017.09.004>.
- [107] K.P. Murphy, *Machine Learning: A Probabilistic Perspective*, MIT Press, 2012.
- [108] A. Singh, N. Thakur, A. Sharma, A review of supervised machine learning algorithms, in: *2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom)*, 2016: pp. 1310–1315.

Références bibliographiques

- [109] M.A. DeRousseau, J.R. Kasprzyk, W.V. Srubar, Computational design optimization of concrete mixtures: A review, *Cement and Concrete Research*. 109 (2018) 42–53. <https://doi.org/10.1016/j.cemconres.2018.04.007>.
- [110] Y.-K. Kim, K.-S. Na, Application of machine learning classification for structural brain MRI in mood disorders: Critical review from a clinical perspective, *Progress in Neuro-Psychopharmacology and Biological Psychiatry*. 80 (2018) 71–80. <https://doi.org/10.1016/j.pnpbp.2017.06.024>.
- [111] H. Salehi, R. Burgueño, Emerging artificial intelligence methods in structural engineering, *Engineering Structures*. 171 (2018) 170–189. <https://doi.org/10.1016/j.engstruct.2018.05.084>.
- [112] İ.B. Topçu, M. Saridemir, Prediction of mechanical properties of recycled aggregate concretes containing silica fume using artificial neural networks and fuzzy logic, *Computational Materials Science*. 42 (2008) 74–82. <https://doi.org/10.1016/j.commatsci.2007.06.011>.
- [113] Z.H. Duan, S.C. Kou, C.S. Poon, Prediction of compressive strength of recycled aggregate concrete using artificial neural networks, *Construction and Building Materials*. 40 (2013) 1200–1206. <https://doi.org/10.1016/j.conbuildmat.2012.04.063>.
- [114] A.T.A. Dantas, M. Batista Leite, K. de Jesus Nagahama, Prediction of compressive strength of concrete containing construction and demolition waste using artificial neural networks, *Construction and Building Materials*. 38 (2013) 717–722. <https://doi.org/10.1016/j.conbuildmat.2012.09.026>.
- [115] T. Kalman Šipoš, I. Miličević, R. Siddique, Model for mix design of brick aggregate concrete based on neural network modelling, *Construction and Building Materials*. 148 (2017) 757–769. <https://doi.org/10.1016/j.conbuildmat.2017.05.111>.
- [116] A. Hendi, A. Behravan, D. Mostofinejad, A. Sedaghatdoost, M. Amini, A step towards green concrete: Effect of waste silica powder usage under HCl attack, *Journal of Cleaner Production*. 188 (2018) 278–289. <https://doi.org/10.1016/j.jclepro.2018.03.288>.
- [117] M. Singh, A. Srivastava, D. Bhunia, An investigation on effect of partial replacement of cement by waste marble slurry, *Construction and Building Materials*. 134 (2017) 471–488. <https://doi.org/10.1016/j.conbuildmat.2016.12.155>.
- [118] M.N.S. Hadi, M. Al-Azzawi, T. Yu, Effects of fly ash characteristics and alkaline activator components on compressive strength of fly ash-based geopolymer mortar, *Construction and Building Materials*. 175 (2018) 41–54. <https://doi.org/10.1016/j.conbuildmat.2018.04.092>.
- [119] S. Chithra, S.R.R.S. Kumar, K. Chinnaraju, F. Alfin Ashmita, A comparative study on the compressive strength prediction models for High Performance Concrete containing nano silica and copper slag using regression analysis and Artificial Neural Networks, *Construction and Building Materials*. 114 (2016) 528–535. <https://doi.org/10.1016/j.conbuildmat.2016.03.214>.
- [120] A.O. Sojobi, O.J. Aladegboye, T.F. Awolusi, Green interlocking paving units, *Construction and Building Materials*. 173 (2018) 600–614. <https://doi.org/10.1016/j.conbuildmat.2018.04.061>.
- [121] H. Eskandari-Naddaf, R. Kazemi, ANN prediction of cement mortar compressive strength, influence of cement strength class, *Construction and Building Materials*. 138 (2017) 1–11. <https://doi.org/10.1016/j.conbuildmat.2017.01.132>.
- [122] H. Erdem, Predicting the moment capacity of RC beams exposed to fire using ANNs, *Construction and Building Materials*. 101 (2015) 30–38. <https://doi.org/10.1016/j.conbuildmat.2015.10.049>.
- [123] H. Mashhadban, S.S. Kutanaei, M.A. Sayarinejad, Prediction and modeling of mechanical properties in fiber reinforced self-compacting concrete using particle swarm optimization algorithm and artificial neural network, *Construction and Building Materials*. 119 (2016) 277–287. <https://doi.org/10.1016/j.conbuildmat.2016.05.034>.
- [124] H. Naderpour, A.H. Rafiean, P. Fakharian, Compressive strength prediction of environmentally friendly concrete using artificial neural networks, *Journal of Building Engineering*. 16 (2018) 213–219. <https://doi.org/10.1016/j.job.2018.01.007>.
- [125] Q. Zhou, F. Wang, F. Zhu, Estimation of compressive strength of hollow concrete masonry prisms using artificial neural networks and adaptive neuro-fuzzy inference systems, *Construction and Building Materials*. 125 (2016) 417–426. <https://doi.org/10.1016/j.conbuildmat.2016.08.064>.

Références bibliographiques

- [126] G. Dogan, M.H. Arslan, M. Ceylan, Concrete compressive strength detection using image processing based new test method, *Measurement*. 109 (2017) 137–148. <https://doi.org/10.1016/j.measurement.2017.05.051>.
- [127] E. Momeni, R. Nazir, D. Jahed Armaghani, H. Maizir, Prediction of pile bearing capacity using a hybrid genetic algorithm-based ANN, *Measurement*. 57 (2014) 122–131. <https://doi.org/10.1016/j.measurement.2014.08.007>.
- [128] D.J. Armaghani, E.T. Mohamad, M.S. Narayanasamy, N. Narita, S. Yagiz, Development of hybrid intelligent models for predicting TBM penetration rate in hard rock condition, *Tunnelling and Underground Space Technology*. 63 (2017) 29–43. <https://doi.org/10.1016/j.tust.2016.12.009>.
- [129] W.P.S. Dias, S.P. Pooliyadda, Neural networks for predicting properties of concretes with admixtures, *Construction and Building Materials*. 15 (2001) 371–379. [https://doi.org/10.1016/S0950-0618\(01\)00006-X](https://doi.org/10.1016/S0950-0618(01)00006-X).
- [130] B. Boukhatem, S. Kenai, A.T. Hamou, Dj. Ziou, M. Ghrici, Predicting concrete properties using neural networks (NN) with principal component analysis (PCA) technique, *Computers and Concrete*. 10 (2012) 557–573. <https://doi.org/10.12989/CAC.2012.10.6.557>.
- [131] A.B. Goktepe, G. Inan, K. Ramyar, A. Sezer, Estimation of sulfate expansion level of PC mortar using statistical and neural approaches, *Construction and Building Materials*. 20 (2006) 441–449. <https://doi.org/10.1016/j.conbuildmat.2005.01.041>.
- [132] E. Hewayde, M. Nehdi*, E. Allouche, G. Nakhla, Neural network prediction of concrete degradation by sulphuric acid attack, *Structure and Infrastructure Engineering*. 3 (2007) 17–27. <https://doi.org/10.1080/15732470500253065>.
- [133] S.S.Y. Lam, K.L. Petri, A.E. Smith, Prediction and optimization of a ceramic casting process using a hierarchical hybrid system of neural networks and fuzzy logic, *IIE Transactions*. 32 (2000) 83–91. <https://doi.org/10.1023/A:1007659531734>.
- [134] S. Akkurt, G. Tayfur, S. Can, Fuzzy logic model for the prediction of cement compressive strength, *Cement and Concrete Research*. 34 (2004) 1429–1433. <https://doi.org/10.1016/j.cemconres.2004.01.020>.
- [135] T. Uygunoglu, O. Unal, A new approach to determination of compressive strength of fly ash concrete using fuzzy logic, *JSIR Vol.65(11)* [November 2006]. (2006). <http://nopr.niscair.res.in/handle/123456789/4954> (accessed March 30, 2021).
- [136] I.-J. Han, T.-F. Yuan, J.-Y. Lee, Y.-S. Yoon, J.-H. Kim, Learned Prediction of Compressive Strength of GGBFS Concrete Using Hybrid Artificial Neural Network Models, *Materials*. 12 (2019) 3708. <https://doi.org/10.3390/ma12223708>.
- [137] S. Abdelfeteh, Formulation de matériaux de construction à base de sous-produits industriels avec des méthodes issues de l'intelligence artificielle, Thèse de doctorat, Lille 1, 2016. <http://www.theses.fr/2016LIL10077> (accessed May 21, 2021).
- [138] G. Roquier, Etude de la compacité optimale des mélanges granulaires binaires: classe granulaire dominante, effet de paroi, effet de desserrement, (n.d.) 640.
- [139] N. Pouliot, T. Sedran, F. de LARRARD, J. Marchand, Prédiction de la compacité des bétons compactés au rouleau à l'aide d'un modèle d'empilement granulaire, (2001) 14.
- [140] A. Sadok, R. Zentar, N.-E. Abriak, Genetic programming for granular compactness modelling, *European Journal of Environmental and Civil Engineering*. 20 (2016) 1249–1261. <https://doi.org/10.1080/19648189.2016.1150901>.
- [141] Essai de compacité des fractions granulaires à la table à secousses: mode opératoire., Laboratoire central des ponts et chaussées, Paris, 2004.
- [142] W. Hanini, Etude comparative de la compacité expérimentale et prévisionnelle des milieux granulaires, 11 (2015) 8.
- [143] L. Berga, J.M. Buil, C. Jofré, S. Chonggang, *Roller Compacted Concrete Dams*, Taylor & Francis, Spanish, 2003.
- [144] G. Dreux, J. Festa, *Nouveau guide du béton et de ses constituants*, 8th ed., Eyrolles, Paris, 1998.

Références bibliographiques

- [145] M.N. Alam, B. Das, V. Pant, A comparative study of metaheuristic optimization approaches for directional overcurrent relays coordination, *Electric Power Systems Research*. 128 (2015) 39–52. <https://doi.org/10.1016/j.epsr.2015.06.018>.
- [146] T. SEDRAN, Rhéologie et rhéométrie des bétons. Application aux bétons autonivelants, 1999.
- [147] A. Lecomte, M. de Conférences, J.-M. Mechling, Compacité des mélanges et propriétés des grains, (n.d.) 13.
- [148] F. de Larrard, T. Sedran, Une nouvelle approche de la formulation des bétons, (n.d.) 25.
- [149] International Federation for Structural Concrete, ed., Model Code 2010: first complete draft. Vol. 1: ..., International Federation for Structural Concrete, Lausanne, 2010.
- [150] Hybrid Artificial Intelligence Model Development for Roller-compacted Concrete Compressive Strength Estimation, *IJE*. 33 (2020). <https://doi.org/10.5829/ije.2020.33.10a.04>.
- [151] Y. Chakali, A.H. Sadok, M. Tahlaïti, T. Nacer, A PSO-ANN Intelligent Hybrid Model to Predict the Compressive Strength of Limestone Fillers Roller Compacted Concrete (RCC) to Build Dams, *KSCE Journal of Civil Engineering*. (2021) 11. <https://doi.org/10.1007/s12205-021-1531-6>.
- [152] R. Dupain, R. Lanchon, J. Saint-Arroman, Granulat, sols, ciments et betons, CASTEILLA, PARIS, 2004.
- [153] Groupement belge du béton, Technologie du béton., 4th ed., Groupement belge du béton, Bruxelles, 2006.
- [154] Z. Didouche, K. Ezziane, E.-H. Kadri, Predicted of hydration heat and compressive strength of limestone cement mortar with different type of superplasticizer, *Advances in Concrete Construction*. 6 (2018) 659–677. <https://doi.org/10.12989/ACC.2018.6.6.659>.
- [155] D. Liu, Z. Li, J. Liu, Experimental study on real-time control of roller compacted concrete dam compaction quality using unit compaction energy indices, *Construction and Building Materials*. 96 (2015) 567–575. <https://doi.org/10.1016/j.conbuildmat.2015.08.048>.
- [156] E. Şengün, B. Alam, R. Shabani, I.O. Yaman, The effects of compaction methods and mix parameters on the properties of roller compacted concrete mixtures, *Construction and Building Materials*. 228 (2019) 116807. <https://doi.org/10.1016/j.conbuildmat.2019.116807>.