

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université Hassiba Benbouali de Chlef

Faculté de Génie Civil et d'Architecture

Département de Génie Civil



THÈSE

Présentée pour l'obtention du diplôme de

DOCTORAT EN SCIENCES

Spécialité : Génie Civil

Par

Redouane REBOUH

Thème :

ELABORATION D'UN LOGICIEL DE FORMULATION DES BETONS

CONTENANT DES AJOUTS CIMENTAIRES

#

Soutenue le 22 Février 2018, devant le jury composé de :

Zamila HARICHANE	Professeur	UHB de Chlef	Présidente
Karim EZZIANE	Professeur	UHB de Chlef	Examineur
Said KENAI	Professeur	USD de Blida	Examineur
Mohamed ABED	Professeur	USD de Blida	Examineur
Mohamed GHRICI	Professeur	UHB de Chlef	Rapporteur
Arezki TAGNIT-HAMOU	Professeur	Université de Sherbrooke	Co-Rapporteur

Dédicaces

*J'ai le plaisir de dédier le fruit de mes années d'étude
et du sérieux que j'ai fait à tous ce qui on sacrifie*

En premier lieu

Aux êtres les plus chers au monde ma « Mère »

Symbole de tendresse

et mon « Père »

Pour le dévouement qui ont consenti afin que je puisse atteindre cet objectif.

A ma femme, mon Frère et mes Sœurs

A toutes les Familles « REBOUH », « BEN GOUFA »

Et « DERDER »

A tous mes amis

Enfin

à tous qui m'ont aidé et merci a tous.

REBOUH REDOUANE

Remerciements

Je voudrais saisir l'occasion qui m'est offerte pour exprimer ma profonde gratitude et tous mes remerciements à mes promoteurs Monsieur Mohamed GHRICI professeur à l'Université Hassiba Ben-Bouali de Chlef et Dr Bakhta BOUKHATEM, Maîtres de Conférences à l'Université Hassiba Ben-Bouali de Chlef, pour leur dévouement, leurs précieux conseils, leurs critiques constructives et leur intérêt qu'ils ont porté tout au long de l'élaboration de ce travail.

Je tiens à remercier infiniment Monsieur Arezki TAGNIT-HAMOU professeur à l'Université de Sherbrooke à CANADA, pour l'accueil qu'il m'a réservé dans son laboratoire ainsi que pour la confiance qu'il m'a confiée, aussi d'avoir accepté d'examiner avec toute l'attention voulue le présent travail.

Il m'est particulièrement agréable de remercier sincèrement Madame Zamila HARICHANE, professeur à l'Université Hassiba Ben-Bouali de Chlef, d'avoir accepté de présider le jury d'examen.

Je tiens à remercier et à exprimer toute ma gratitude au Messieurs Said KENAI et Mohamed ABED, professeurs à l'Université de Blida et Monsieur Karim EZZIANE, professeur à l'Université de Chlef, pour avoir accepté d'examiner le présent travail avec toute l'attention voulue.

J'exprime également mes remerciements à Mr Khélifa HARICHANE, professeur à l'Université de Chlef pour son aide précieuse et sa compréhension durant toute la période de la préparation du mémoire.

Je tiens aussi à exprimer mes sincères remerciements à l'ensemble des enseignants du faculté de Génie Civil et d'architecture à l'Université Hassiba Ben Bouali de Chlef et en particulier les enseignants de post graduation qui ont contribué à ma formation de Magister.

Enfin, je souhaite adresser mes remerciements à tous ceux qui par leur aide et leur soutien m'ont permis de réaliser cette étude.

Résumé

La conception de mélange du béton consiste en la sélection des proportions de ses constituants pour avoir certaines propriétés désirées. Le processus est devenu plus compliqué avec l'introduction de nouveaux constituants tels que les adjuvants minéraux et chimiques et les fibres. Plusieurs chercheurs s'intéressent à la prédiction des propriétés du béton, ce qui se traduit par un nombre élevé d'équations de régression linéaire et non linéaire. Alternativement, d'autres modèles ont été développés par des systèmes plus sophistiqués pour l'optimisation des fonctions en utilisant les algorithmes génétiques (AG), les réseaux de neurone artificiels (RNAs) ou leur combinaison (RNAG). Dans cette étude, on a proposé une structure évolutionnaire qui intègre les algorithmes génétique pour optimiser les poids de connexion et les seuils de chaque neurone du réseau RNA. A cet effet, trois modèles ont été développés ; deux modèles (M1 et M2) pour la prédiction de la résistance à la compression et un modèle (M3) pour la formulation du béton. Plus de 750 données expérimentales collectées des travaux antérieurs ont été utilisées pour l'ajustement et la validité de ces modèles. Ainsi, la validation expérimentale effectuée pour les deux modèles M1 et M2 a prouvé leurs capacités de généralisation avec des coefficients de détermination R^2 de 0,93 et 0,94 respectivement. Pour la conception de mélange, le modèle M3 permet une sélection plus rapide et plus précise des proportions appropriées du béton pour avoir une ouvrabilité et une résistance à la compression requises pour un dosage donné de cendres volantes. En fin, une interface graphique a été élaborée pour réduire de manière significative le nombre d'expériences au laboratoire.

Mots clés : béton, ajouts cimentaire, formulation, pouzzolane naturelle, cendres volantes, prévision, résistance à la compression, réseaux de neurones, Algorithme Génétique, hybride RNAG.

Abstract

The concrete mix design consists in the selection of its constituents proportions to have certain desired properties. The process has become more complicated due to the introduction of new constituents such as mineral and chemical additives and fibers. Several researchers are interested in concrete properties prediction, which results in a large number of linear and nonlinear regression equations. Alternatively, other models have been developed by more sophisticated systems by the optimization of functions using genetic algorithms (GA), artificial neural networks (ANNs) or their combination (NNGA). In this study, we proposed an evolutionary structure that integrates genetic algorithms to optimize the connection weights and the thresholds of each neuron in the ANN network. For this purpose, three models have been developed; two models (M1 and M2) for the prediction of the compressive strength and a model (M3) for the concrete mix design. More than 750 experimental data collected from previous work were used for the adjustment and validation of these models. Thus, the experimental validation carried out for the two models M1 and M2 proved their generalization capacities with determination coefficients R^2 of 0.93 and 0.94, respectively. For the mix design, the model M3 allows a faster and more accurate selection of appropriate concrete proportions in order to obtain the required workability and compressive strength for a given fly ash content. Finally, a graphical interface has been developed to reduce significantly the number of laboratory experiments.

Key words: concrete, cementitious additions, mix design, natural pozzolan, fly ash, prediction, compressive strength, neural network, genetic algorithms, hybrid NNGA.

الملخص

تصميم الخليط الخرساني يهدف الى اختيار نسب مكوناته للحصول على بعض الخصائص المرجوة. وقد أصبحت العملية أكثر تعقيدا مع إدخال مكونات جديدة مثل الإضافات المعدنية والكيميائية والألياف. يهتم العديد من الباحثين بتنبؤ خصائص الخرسانة وهذا ما أدى إلى انجاز إلى عدد كبير من معادلات الانحدار الخطية وغير الخطية. بدلا من ذلك، تم تطوير نماذج أخرى من قبل أنظمة أكثر تطورا لتحسين الوظيفة باستخدام الخوارزميات الجينية، الشبكات العصبية الاصطناعية أو مزيجها. في هذه الدراسة، اقترحنا بنية تطويرية بدمج الخوارزميات الجينية لتحسين أوزان الاتصال وعتبات كل الخلايا العصبية في الشبكات العصبية. ولهذا الغرض، تم تطوير ثلاثة نماذج؛ (M1 و M2) للتنبؤ بمقاومة الانضغاط ونموذج (M3) لتصميم الخليط الخرساني. تم استخدام أكثر من 750 من البيانات التجريبية التي تم جمعها من الأعمال السابقة من أجل التأكد من ملاءمة وصحة هذه النماذج. تم التحقق من صحة نماذج التنبؤ المختلطة المقترحة تجريبيا مع نتائج إيجابية مقبولة جدا مع R^2 يساوي 0.93 و 0.94، للنماذج M1 و M2 على التوالي، ويمكن للنموذج M3 ان يؤدي إلى اختيار بسرعة وبدقة عالية نسب مكونات وفقا لاثنتين من الخصائص الرئيسية التي تميز بها الخرسانة: قابلية التشغيل، القوة ضد الضغط والكمية المطلوبة من الرماد المتطاير وأخيرا، تم تطوير واجهة المستخدم للنظام للحد بشكل كبير من عدد التجارب المختبرية.

كلمات دلالية: الخرسانة، الإضافات الاسمنتية، تصميم الخليط الخرساني، البوزولان الطبيعية، الرماد المتطاير، التنبؤ، قوة الضغط، الشبكة العصبية، الخوارزميات الجينية، شبكة الاعصاب الاصطناعية الهجينة.

TABLE DES MATIERES

Liste des Figures	V
Liste des Tableaux	X
Liste des abréviations.....	XI

Introduction Générale

Généralités	2
But de travail.....	4
Plan des chapitres.....	5

Chapitre 1

Techniques de l'intelligence Artificielle

1. Introduction	7
1.2 Branches de l'intelligence Artificiel	7
1.3 Algorithme Génétique (AG)	8
1.3.1 Terminologie basique des algorithmes génétiques	8
1.3.2 Principe de base	9
1.3.3 Fonctionnement d'un algorithme génétique	10
1.3.4 Codage d'un individu.....	11
1.3.5 Génération de la population initiale.....	12
1.3.6 Fonction de fitness ou d'évaluation.....	12
1.3.7 Opérateurs des algorithmes génétiques.....	13
1.3.7.1 Sélection	13
1.3.7.2 Croisement	14
1.3.7.3 Mutation	15
1.3.8 Avantages majeurs des algorithmes génétiques.....	15
1.4 Réseaux de neurones Artificiels.....	16
1.4.1 Théorie et définitions des Réseaux de Neurones Artificiel	16
1.4.2 Neurone artificiel (formel)	17
1.4.3 Concepts de base.....	18
1.4.4 Réseaux de neurones non boucle (ou statique) "FEED-FORWARD"	19

1.4.5 Apprentissage d'un réseau de neurones	21
1.4.5.1 Principe de l'algorithme d'apprentissage	21
1.4.5.2 Différents types d'apprentissage	22
1.4.6 Avantage et limites des réseaux de neurones.....	23
1.5 Théorie de logique floue	24
1.5.1 Définition de la logique floue	24
1.5.2 Avantage et limites de la logique floue.....	26
1.6 System hybride algorithmes génétiques et réseaux de neurones « RNAG »	26
1.6.1 Hybridation neuro-floue	27
1.6.2 Comparaison entre la BP, GA et méthode hybride (GA + BP)	28
1.7 Conclusion	29

Chapitre 2

Application de l'intelligence Artificielle dans la Technologie de béton

2.1. Introduction	31
2.2 Utilisation des AGs et les RNAs dans le domaine de Génie Civil	31
2.3 Objectifs de la formulation d'un béton	32
2.4 Application d'IA dans la technologie des Bétons.....	32
2.4.1 Application des algorithmes génétiques	32
2.4.2 Application des Réseau de neurone	38
2.4.3 Application du système hybride RNAG	48
2.5 Conclusion	52

Chapitre 3

Conception de la Base de Données

3.1. Introduction	54
3.2 Méthodologie de collection et d'organisation des données expérimentales.....	54
3.3 Organisation de la base de données	61
3.4 Normalisation des Données	63
3.5 Conclusion	63

Chapitre 4

Développement des modèles et conception du logiciel de formulation

4.1. Introduction.....	66
4.2 Méthodologie de développement des modèles RNAG.....	66
4.3 Développement de la structure hybride RNAG	67
4.3.1 Détermination des paramètres de RNA	68
4.3.2 Hybridation AG et RNA	70
4.4 Modèles de formulation et de prévision de la résistance	73
4.4.1 Résistance à la compression du béton.....	73
4.4.2 Ouvrabilité du béton	74
4.5 Définition des entrées et des sorties des modèles.....	75
4.6 Développement du modèle M1 pour le béton à la pouzzolane naturelle	78
4.6.1 Mécanisme d'optimisation de l'architecture du modèle M1	79
4.6.1.1 Encodage et génération de la population initiale.....	79
4.6.1.2 Application des opérateurs d'AG	80
4.6.1.3 Fonctions d'évaluation	81
4.6.2 Evaluation de la performance du modèle hybride RNAG.....	82
4.7 Développement des Modèles pour le béton aux cendres volantes.....	85
4.7.1 Modèle de prévision de la résistance à la compression M2.....	85
4.7.2 Modèle de formulation des bétons à la cendre volante M3	86
4.8 Interface adoptée pour les modèles développés.....	88
4.9 Conclusion	93

Chapitre 5

Validation expérimentale des modèles développés

5.1. Introduction	95
5.2 Procédure et déroulement des essais.....	95
5.2.1 Matériaux utilisés.....	95
5.2.2 Composition des bétons coulés.....	98
5.2.3 Procédures expérimentales	99
5.3 Essais à l'état frais et durci	100
5.3.1 Mesure de l'ouvrabilité	100

5.3.2 Masse Volumique et teneur en air	101
5.3.3 Résistance à la compression	101
5.4 Présentation et analyse des résultats	101
5.4.1 Etat frais	101
5.4.2 Etat durci.....	102
5.5 Validation des modèles de prévision de la résistance développées (M1 et M2)	107
5.6 Validation du modèle de formulation de béton développé (M3)	110
5.7 Conclusion	112

Chapitre 6

Performances des modèles développés

6.1. Introduction	114
6.2 Généralisation des modèles RN développés.....	114
6.3 Résultats et discussions.....	117
6.3.1 Modèle de prévision de la résistance à la compression M1.....	117
6.3.1.1 Effet du rapport E/C	117
6.3.1.2 Effet du l'age et le taux de pouzzolane sur la résistance a la compression.....	119
6.3.2 Modèle de prévision de la résistance à la compression M2.....	121
6.3.2.1 Effet du rapport E/C	121
6.3.2.2 Effet de Cendre volante.....	121
6.3.3 Formulation des Bétons aux cendres volantes vis-à-vis la résistance et l'ouvrabilité « M3 »	125
6.3.3.1 Effet de rapport E/L sur la résistance	130
6.3.3.2 Effet du type de cendre volante sur la résistance	133
6.4 Conclusion	134

Conclusions Générales et Recommandations

Conclusions générales.....	137
Recommandations.....	138

Références Bibliographiques	141
--	-----

Liste des Figures

Figure 1.1	Différents branches de l'intelligence Artificiel	7
Figure 1.2	Terminologie basique des AGs.....	9
Figure 1.3	Processus d'un algorithme génétique	10
Figure 1.4	Codage d'un individu par chaine binaire.....	12
Figure 1.5	Codage d'un individu par chaine de bits réels.....	12
Figure 1.6	Exemple de sélection par Roulettes biaisée.....	13
Figure 1.7	Exemple de sélection type Tourneement.....	14
Figure 1.8	Opérateurs basiques des algorithmes génétiques (croisement)	14
Figure 1.9	Opérateurs basiques des algorithmes génétiques (Mutation)	15
Figure 1.10	Modélisation simplifiée du neurone biologique	17
Figure 1.11	Type de fonctions d'activations.....	19
Figure 1.12	Perceptron Multicouches	20
Figure 1.13	Apprentissage supervisé	22
Figure 1.14	Apprentissage non-supervisé	22
Figure 1.15	Problème des minima locaux.....	24
Figure 1.16	Représentation graphique d'un ensemble classique et d'un ensemble flou.....	25
Figure 1.17	Comparaison entre la BP, GA et GA + BP.....	28
Figure 2.1	Distribution des publications par ans dans le journal JCCE.....	31
Figure 2.2	Performance du modèle PG par rapport aux résultats de test.....	33
Figure 2.3	Prévision de la résistance à la compression du BAP en fonction de rapport E/L.....	34
Figure 2.4	Prévision de la résistance à la compression en fonction d'âge.....	34
Figure 2.5	Processus de développement du modèle	35
Figure 2.6	Relation entre l'erreur et nombre d'itération.....	36
Figure 2.7	Modèles de prévision de la résistance à la compression proposées par Chopra et al., (2016).....	37
Figure 2.8	Architecture du réseau développé par Oh et al., (1999).....	38
Figure 2.9	Modèle de RNA proposé par Öztaş et al., (2006).....	40
Figure 2.10	Comparaison entre la résistance expérimentale et la résistance prédite par les RNAs	41
Figure 2.11	Comparaison entre l'ouvrabilité expérimentale et l'ouvrabilité prédite par les RNAs.....	42

Figure 2.12	Distribution d'erreur de la phase test pour l'ouvrabilité	42
Figure 2.13	Distribution d'erreur de la phase de test pour la résistance.....	42
Figure 2.14	Architecture du modèle de prévision	43
Figure 2.15	Architectures proposées pour la prévision de la résistance.....	44
Figure 2.16	Comparaison entre les valeurs la résistance expérimentales de RNA-1 et RNA-2	45
Figure 2.17	Architecture du Modèle RN	46
Figure 2.18	Relation linéaire entre les propriétés expérimentales et prévues pour BAP.....	47
Figure 2.19	Architecture du modèle proposé par Chandwani et al. (2015).....	50
Figure 2.20	Régression entre les valeurs d'ouvrabilités prédit par RNA (a) et RNAG (b) et les valeurs observées	50
Figure 2.21	Organigramme de système RNA assisté par AG.....	51
Figure 4.1	Méthodologie suivie pour le développement du modèle hybride RNAG	67
Figure 4.2	Code Matlab pour la Création de réseau de neurone.....	69
Figure 4.3	Encodage binaire	70
Figure 4.4	Encodage réel des poids et les bais d'un réseau de neurone	71
Figure 4.5	Code Matlab pour l'hybridation RNAG.....	72
Figure 4.6	Différents classes de l'ouvrabilité	74
Figure 4.7	Relation entre CaO et la somme de $SiO_2+Al_2O_3+Fe_2O_3$ de 110 types de CV de l'Amérique de nord.....	77
Figure 4.8	Identification de l'Indice D selon ASTM 618	77
Figure 4.9	Architecture du modèle de prévision « M1 »	78
Figure 4.10	Encodage de l'architecture du RN.....	80
Figure 4.11	Operateur de croisement.....	81
Figure 4.12	Operateur de Mutation.....	81
Figure 4.13	Corrélation obtenus pour les différentes phases (Apprentissage, Validation et Teste) de RN optimisé	84
Figure 4.14	Architecture du modèle de prévision « M2 »	85
Figure 4.15	Architecture du modèle de prévision « M3 »	87
Figure 4.16	Interface graphique du logiciel CMSv01.....	89
Figure 4.17	Menu principal du logiciel de prévision de la résistance à la compression.....	90
Figure 4.18	Fenêtre de prévision de la résistance à la compression (Modèle M1)	91
Figure 4.19	Menu principal du logiciel de sous-logiciel de formulation « M3 »	91
Figure 4.20	Menu d'exécution sous-logiciel de formulation « M3 »	92

Figure 5.1	Courbes granulométriques du sable utilisé.....	97
Figure 5.2	Courbes granulométriques des granulats 5/14 utilisés	98
Figure 5.3	Mesure d'ouvrabilité avec cône d'Abrams.....	100
Figure 5.4	Mesure la teneur en Air et la masse volumique.....	101
Figure 5.5	Effet de taux de PN et le rapport E/L sur la résistance à la compression.....	104
Figure 5.6	Effet de taux de CV et le rapport E/L sur la résistance à la compression.....	106
Figure 5.7	Comparaison de la résistance à la compression observée et prédite par les modèles : (a) M. (b) ACI et (c) CEB	108
Figure 5.8	Comparaison de la résistance à la compression observée et prédite par les modèles : (a) M2. (b) ACI et (c) CEB	109
Figure 6.1	Effet du rapport E/L sur la résistance à la comperssion	118
Figure 6.2	Effet de l'age et de la pouzzolane sur la résistance à la compression	120
Figure 6.3	Effet du rapport E/L sur la résistance à la comperssion à 28 jours.....	121
Figure 6.4	Effet de l'age sur la résistance à la comperssion des bétons à base de CV	122
Figure 6.5	Effet de cendre volante sur le développement de la résistance à la compression.....	123
Figure 6.6	Effet de type de cendre volante sur le développement de la résistance.....	124
Figure 6.7	Variation du rapport E/L en fonction de la résistance à 28 jours pour différent rapport G/Gr avec D =25 et Ouvrabilité = 10cm.....	131
Figure 6.8	Variation du liant en fonction de la résistance à 28 jours pour différent rapport G/Gr avec D =25 et Ouvrabilité = 10cm	132
Figure 6.9	Variation de rapport E/L en fonction de la résistance à 90 jours pour pour D =25 et 5 avec une Ouvrabilité de 10cm	134

Liste des Tableaux

Tableau 1.1	Exemple d'illustration logique flou.	24
Tableau 1.2	Nombre des publications qui contiennent le mot clé « hybrid genetic et hybrid evolutionary »	27
Tableau 2.1	Paramètres statistiques des formulations basés sur les modèles élaborés.	35
Tableau 2.2	Résultats d'erreur obtenue par AG.	36
Tableau 2.3	Paramètres choisis pour l'AG.	37
Tableau 2.4	Résultats du Modèle AG de prévision.	38
Tableau 2.5	Résultats de l'apprentissage et de test.	39
Tableau 2.6	Paramètre d'entrée de la base de données.	40
Tableau 2.7	Les paramètres utilisés dans le modèle de réseau de neurones.	41
Tableau 2.8	Données utilisées pour l'apprentissage et tests.	44
Tableau 2.9	Paramètres des deux modèles de réseau neurone.	45
Tableau 2.10	Comparaison des résultats prédits par le Modèle RN1 et les résultats d'autres chercheurs.	48
Tableau 2.11	Gammes de composants des ensembles de données.	49
Tableau 3.1	Exemple d'un vecteur de facteurs influençant sur la formulation	55
Tableau 3.2	Gammes des constituants et propriétés des bétons aux PN	56
Tableau 3.3	Gammes des constituants et propriétés des bétons aux CV	56
Tableau 3.4	Composition chimique des ciments utilisés avec la pouzzolane naturelle	57
Tableau 3.5	Compositions chimiques et surfaces massiques des pouzzolanes naturelle	58
Tableau 3.6	Composition chimique des ciments utilisés pour les bétons aux cendres volantes	59
Tableau 3.7	Compositions chimiques et surfaces massiques des cendres volantes.	60
Tableau 3.8	Organisation de la base des données des modèles de prévision de la résistance pour les bétons à la PN.	62
Tableau 3.9	Organisation de la base des données des modèles de prévision de la résistance et de formulation pour les bétons aux CVs	62

Tableau 4.1	Diffèrent classe de béton et utilisation.....	73
Tableau 4.2	Classification de la consistance en fonction de l'affaissement au cône.....	75
Tableau 4.3	Paramètre Input et output des modèles proposés.....	76
Tableau 4.4	Les paramètres utilisés pour l'apprentissage du RNA.....	79
Tableau 4.5	Paramètres utilise pour AG.....	82
Tableau 4.6	Comparaison entre le RNA et le RNAG.....	83
Tableau 4.7	Les paramètres utilisés pour l'apprentissage du RNA.....	86
Tableau 4.8	Paramètres utilisés pour AG.....	86
Tableau 4.9	Les paramètres utilisés pour l'apprentissage du RNA.....	88
Tableau 4.10	Paramètres utilise pour AG.....	88
Tableau.5.1	Composition chimique du ciment et de la pouzzolane naturelle utilisés dans le premier programme expérimental.....	95
Tableau.5.2	Composition chimique de ciment et des cendres volantes utilisées.....	97
Tableau.5.3	Caractéristiques physiques du sable naturel et des granulats utilisés.....	97
Tableau.5.4	Formulations des bétons contenant de la PN.....	99
Tableau.5.5	Formulations des bétons contenant de la CV.....	100
Tableau.5.6	Propriétés du béton à l'état frais.....	102
Tableau.5.7	Résistance à la compression des Béton contenant de PN.....	103
Tableau.5.8	Résistance à la compression des Béton contenant de CV.....	105
Tableau.5.9	Comparaison entre les modèles M1 et M2 développées et le les formules proposé par ACI et CEB.....	110
Tableau.5.10	Combinaison d'entrées introduit au modèle.....	111
Tableau.5.11	Erreur absolues moyenne.....	111
Tableau.6.1	Valeurs limites du fonctionnement des Modèles développés.....	115
Tableau.6.2	Vecteur données pour l'étude paramétrique du modèle M1.....	116
Tableau.6.3	Vecteur données pour l'étude paramétrique du modèle M2.....	116
Tableau.6.4	Vecteur données pour l'étude paramétrique du modèle M3.....	117
Tableau.6.5	Formulations obtenus par modèle M3 pour un rapport $G/(G+S) = 0.55$, Indice $D = 25$ (CV classe F) et une ouvrabilité de 10 cm.....	125
Tableau.6.6	Formulations obtenus par modèle M3 pour un rapport $G/(G+S) = 0.6$, Indice $D = 25$ (CV classe F) et une ouvrabilité de 10 cm.....	126

Tableau.6.7	Formulations obtenus par modèle M3 pour un rapport $G/ (G+S) = 0.65$, Indice $D = 25$ (CV classe F) et une ouvrabilité de 10 cm	127
Tableau.6.8	Formulations obtenus par modèle M3 pour un rapport $G/ (G+S) = 0.55$, Indice $D = 5$ (CV classe C) et une ouvrabilité de 10 cm.....	128
Tableau.6.9	Formulations obtenus par modèle M3 pour un rapport $G/ (G+S) = 0.60$, Indice $D = 5$ (CV classe C) et Ouvrabilité de 10 cm	129
Tableau.6.10	Formulations obtenus par modèle M3 pour un rapport $G/ (G+S) = 0.65$, Indice $D = 5$ (CV classe C) et une ouvrabilité de 10 cm.	130

Liste des abréviations

AG	Algorithmes Génétiques
BAP	Béton Auto-Plaçant
BHP	Bétons à Hautes Performances
BP	Réseaux de neurones à rétropropagation
C	Ciment
C/E	Rapport Ciment/ Eau
CV	Cendres volantes pulvérisées
E/L	Rapport Eau/Liant
f	Fonction de Transfer
f'_{cyl}	Résistance à la compression de cylindre
f_{10}	Résistance à la compression d'un cube de 10x10x10 cm
f_a	Résistance à la compression de cube
f_{c28}	Résistance caractéristique de béton a 28 jours
f_{cu}	Résistance à la compression d'un cube de 15x15x15 cm
G	Gravier
G/Gr	Rapport Gravier/granulat
IA	Intelligence Artificielle
Indice D	Classe de cendres volantes
LF	Logique Floue
M1	Modèle de prévision de la résistance à la compression des bétons à base de la Pouzzolane naturelle
M2	Modèle de prévision de la résistance à la compression des bétons à base de cendres volantes.
M3	Modèles de formulations des bétons à base de cendres volantes.
MAPE	Pourcentage d'erreur moyenne absolue
MLP	Perceptron multicouche
MSE	Erreur quadratique moyenne
n	taux d'apprentissage
PG	Programmation génétique
PN	Pouzzolane naturelle
R	Coefficient de corrélation
R^2	Coefficient de détermination
RMSE	Racine de Moyenne de l'erreur carrée.
RN	Réseaux de Neurons
RNAG	Système hybride Réseaux de Neurons Algorithmes Génétiques
RNAs	Réseaux de Neurons Artificiels
RPG	Réseau multicouche à Rétropropagation
S	Sable
SP	Superplastifiant
SSB	Surface spécifique de Blaine
$trianlm ;$	<i>Levenberg Marquardt</i>
W_i	Matrice des poids
α	Momentum
θ_j	Matrice des biais

#

Introduction Générale

#

#

Généralités

Le processus de sélection des ingrédients appropriés du béton et la détermination de leurs quantités relatives dans le but de produire un béton avec des caractéristiques physiques et mécaniques bien définis ; la maniabilité, la résistance et la durabilité, aussi économiquement que possible, est appelé la conception du mélange de béton. La variation de quantité de chaque composant est gouvernée par sa performance requise dans les deux états durant sa fabrication qui sont l'état frais et l'état durci.

La résistance a été depuis longtemps considérée comme la qualité essentielle d'un béton. La résistance à la compression du béton durci qui est généralement considérée comme un indice majeur de ses autres propriétés. Elle dépend de nombreux facteurs, par exemple, la qualité et la quantité de ciment, d'eau et d'agrégats, la compacité et la cure.

La technologie émergente de l'intelligence artificielle (IA) croise plusieurs techniques simulant les processus cognitifs humains. Les Algorithmes Génétiques (AG), la Logique Floue (LF) et les Réseaux de Neurones (RNs) sont parmi les techniques plus connues. L'application de ces dernières contribue à l'amélioration des méthodes conventionnelles existantes. Plusieurs types des modèles de réseaux de neurones ont été appliqués à un éventail de problèmes de prédiction et ont approuvé leur efficacité dans tous les domaines.

Plusieurs travaux de recherche ont été réalisés en utilisant la technique de l'intelligence artificielle dans le domaine de génie civil, leurs application à montrés que sont des outils de simulation et d'optimisation puissants. Plusieurs modèles ont été développés par l'utilisation des réseaux des neurones et les algorithmes génétiques, pour la prévision des propriétés du béton telles que l'ouvrabilité, la résistance à la compression de béton et la durabilité.

Des méthodes conventionnelles pour prévoir la résistance à la compression du béton sont fondamentalement basées sur l'analyse statistique par laquelle beaucoup d'équations linéaires et non-linéaires de régression ont été construites pour modéliser un tel problème de prévision (De Larrard and Sedran, 2007; Bullard et al., 2009; Yeh, 2007). Pour le béton au jeune âge, la littérature met deux méthodes quant au développement de la définition de la fonction de maturité, qui par la suite conduit à l'établissement d'une relation résistance-maturité introduite pour la première fois par Saul et Nurse (1949). Plus tard, Chanvillard, et D'Aloia (1994) décrivent un modèle pour la prévision de la résistance à la compression au jeune âge d'un béton par l'application de la méthode du temps équivalent. Concernent la

prévision de la résistance à 28 jours des bétons, plusieurs contributions, modèles et méthodes ont été développés à partir de la relation de Féret ou de Bolomey. Par ailleurs, d'autres modèles ont été développés en se basant sur d'autres approches.

Dans le domaine de la technologie du béton, plusieurs recherches basées sur des systèmes de RNs ont été développées initialement. Ces applications concernent principalement la formulation (Ji et al., 2006), l'hydratation (Park, 2005), l'ouvrabilité (Yeh, 2006), la résistance à la compression (Ramezani pour and Tarighat, 2001; Boukhatem et al., 2012), le module d'élasticité (Lambros et al., 2003) et la durabilité du béton (Ramezani pour and Tarighat, 2001; Goktepe et al., 2006; Hewayde et al., 2007). Pour la logique floue, les premières applications ont été réalisées par l'industrie cimentaire pour un contrôle intelligent du broyage des fours de cimenterie (Lin et al., 1996). Quelques applications ont été faites pour la prévision de la résistance à la compression du ciment et des bétons contenant des cendres volantes (Akkurt et al., 2004; Uygunoglu and Unal, 2006). L'approche des algorithmes génétiques a été utilisée avec succès dans plusieurs applications de l'ingénierie. Toutefois, ce n'est que récemment qu'ils ont été utilisés dans les recherches d'optimisation sur le béton. Par conséquent, ils ont été utilisés dans des recherches sur le béton pour modéliser la résistance à la compression des bétons ordinaires, de hautes performances, et à l'optimisation des agrégats dans le béton (Sarıdemir, 2011; Chopra et al., 2016; González-Taboada et al., 2016). Ainsi la prévision des propriétés à l'état frais et durci des bétons Auto-plaçant a été aussi appliquée par les AGs (Ozbay et al., 2008; Sonebi and Cevik, 2009).

Actuellement, plusieurs chercheurs s'orientent vers l'adoption de ces approches pour la construction des systèmes plus sophistiqués par combinaison synergiques de l'ensemble de ces techniques. En technologie du béton, on trouve très peu d'applications de cette hybridation et en particulier pour la prédiction des propriétés du béton (Chandwani et al., 2015). La résistance à la compression du béton est la principale propriété étudiée. Dans une autre application, les AGs ont été combinés avec modèle neuronal flou pour la prévision de la résistance à la compression de béton contenant des cendres volantes (Topçu and Sarıdemir, 2008). Très récemment, un modèle RNs à programmation génétique a été récemment développé pour la prévision de la résistance à la compression (Chopra et al., 2016). Généralement, ces applications ont optimisé un RN à rétro-propagation de différentes façons.

Cependant, l'ampleur de cette application n'a rarement osé au-delà des problèmes classiques tels que l'optimisation de fonctions par un algorithme génétique à convergence très lente d'une part ou l'augmentation ou la diminution du nombre de neurones a priori et leurs

connexité grâce à un algorithme d'apprentissage d'autre part. Afin de réaliser la pleine capacité de cette technologie, comme promise par les systèmes de neurones biologiques naturels, les chercheurs doivent prendre le défi de développer des réseaux plus complexes que ceux développés jusqu'ici. La complexité, dans ce sens, exige une structure riche et évoluée du réseau, comme ceux trouvés récemment dans la génétique du système neuronal qui pourrait jouer un rôle important en matière d'adaptation au fur et à mesure de son évolution ce qui peut laisser de penser que son intelligence évolue aussi (McConnell et al., 2013). Cette structure est basée sur l'intégration d'un AG pour optimiser les poids de connexion et les seuils au niveau de chaque neurone de l'architecture du réseau pour minimiser l'erreur, surmonter la convergence vers des optima locaux et permettre une meilleure généralisation du système.

Les fabricants de béton sont soumis à une pression croissante en termes de délais et de coûts. Ces considérations ont poussé plusieurs chercheurs à la construction des modèles et des systèmes d'aide à la formulation des bétons par l'application de différentes approches. Certains produits sont basés sur des méthodes analytiques conventionnelles et d'autres concernent des approches originales. Cependant, la majorité de ses méthodes ne reposent pas sur un corpus scientifique à la fois solide et explicite et n'ont pas de fonction pour effectuer l'optimisation des mélanges de béton. Récemment, plusieurs chercheurs ont appliqué les techniques de l'intelligence artificielles comme les réseaux de neurones pour la construction de leurs logiciels.

L'emploi fréquent des ajouts minéraux (cendres volantes, fumée de silice, laitier, pouzzolane naturelle, etc.) a entraîné l'apparition de normes dont le but est l'uniformisation et la réglementation de leurs conditions d'utilisation. Leur incorporation comme additions minérales dans les matrices cimentaires a été l'objet d'un nombre significatif de recherches au moyen de différentes approches, dans différents pays de par le monde. Des résultats encourageants concernant les propriétés mécaniques et la durabilité du béton ont été obtenus.

But de travail

Le but de cette étude est d'appliquer l'approche non paramétrique de Réseaux Neurones Artificiels et les algorithmes génétiques pour le développement d'un logiciel de formulation des bétons aux ajouts. Cette approche est utilisée en conjonction avec les résultats expérimentaux disponibles dans la littérature. Dans ce contexte, nous montrons dans la présente étude que cette approche est très bénéfique car elle est basée sur des approximations

qui permettent de tenir compte des facteurs essentiels tels que la résistance à la compression, le taux de substitution, le rapport Gravier /Granulats et l'âge du béton.

Pour cela, une nouvelle structure hybride RNAG développée par le logiciel MATLAB version 2014, est employée pour créer le meilleur réseau pour chaque problème (prévision des propriétés ou formulation). Ainsi, une étude paramétrique a été menée pour définir la plage de fonctionnement de ces modèles, ceci est réalisé en étudiant les effets de divers paramètres utilisés dans la construction du réseau. Un programme expérimental a été réalisé pour la validation des modèles et l'évaluation de la performance de chaque modèle. Également, une comparaison des résultats obtenus par ces modèles avec ceux obtenus par les modèles proposés par l'ACI et le CEB a été effectuée.

Enfin, et afin de rendre le modèle plus pratique aux utilisateurs, une interface graphique conviviale a été implémentée sur la base du logiciel DELPHI XE7.

Plan des chapitres

Nous proposons, ici, de décrire les différentes étapes qui ont permis la réalisation de ce travail.

Le chapitre 1 présente des généralités sur l'intelligence artificielle ; différents techniques et approches.

Une synthèse bibliographique sur les travaux réalisés dans le domaine de la technologie de béton à l'aide de l'intelligence artificielle fait l'objet du chapitre 2.

Le chapitre 3 est consacré aux procédures de collecte de données expérimentales pour l'apprentissage des modèles hybrides des réseaux de neurones et des algorithmes génétiques à développer, l'organisation et la normalisation de ces données.

Le chapitre 4 décrit tout d'abord la méthodologie de conception et l'application du modèle de rétropropagation des réseaux de neurones hybride (RNAG) pour le développement des modèles de formulation et de prévision de la résistance à la compression.

La validation expérimentale des modèles développés fait l'objet du chapitre 5.

Le chapitre 6 est consacré pour l'évaluation de la performance des modèles de prévision de la résistance à la compression et de formulation des bétons contenant des ajouts cimentaires.

Des conclusions générales et des recommandations pour des futurs travaux de recherches constituent la dernière partie du mémoire de la thèse.

CHAPITRE 01

Techniques de l'intelligence Artificielle.

1.1 Introduction

L'intelligence artificielle est l'une des nouvelles disciplines de la science et de l'ingénierie en plein développement. Les travaux dans ce domaine ont commencé sérieusement peu après la Seconde Guerre mondiale, L'expression « Intelligence Artificielle (IA) », a été inventée par John McCarthy en 1956 (Konar, 1999).

Dans ce chapitre, nous dressons un état de l'art sur les technique de l'intelligence artificielle en se basant sur les deux techniques utilisées dans le développement du logiciel de formulation des bétons proposé dans cette thèse qui est basé sur les algorithmes génétiques et les réseaux de neurone artificiels

1.2 Branches de l'intelligence Artificielle

L'intelligence artificielle, souvent abrégée avec le sigle IA, est définie, comme étant : la construction de programmes informatiques qui s'adonnent à des tâches qui sont pour l'instant, accomplies de façon plus satisfaisante par des êtres humains car elles demandent des processus mentaux de haut niveau tels que : l'apprentissage perceptuel, l'organisation de la mémoire et le raisonnement critique (Minsky, 2007).

L'intelligence artificielle est une discipline compréhensive qui a été développée en fonction de l'interaction de plusieurs disciplines telles que l'informatique, la cybernétique, la théorie de l'information...etc. C'est une branche de l'informatique, impliquée dans la recherche, la conception et l'application d'ordinateurs intelligents (Lu et al., 2012). Ses différentes techniques sont données par la Figure 1.1.

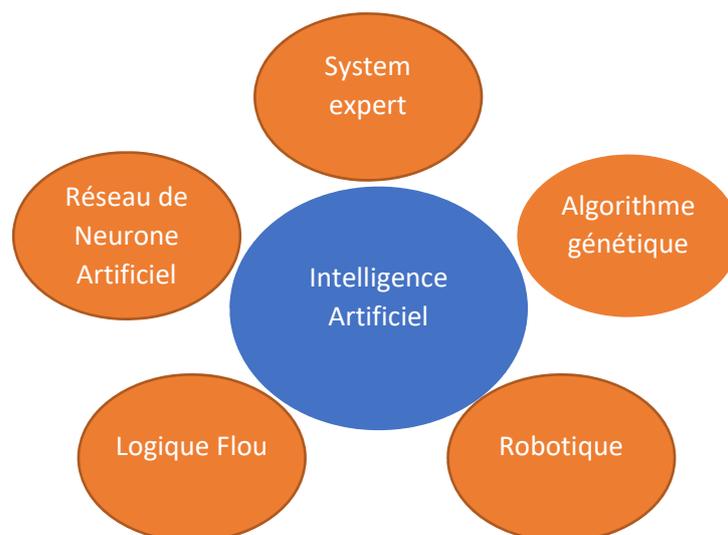


Figure 1.1 – Différents branches de l'intelligence Artificielle

1.3 Algorithme Génétique (AG)

Les algorithmes génétiques (AG) sont des algorithmes d'optimisation stochastique globale basés sur les concepts de la théorie évolutionniste biologique. Ils ont été introduits la première fois dans les années 1975 par John Holland en partant des systèmes évolutifs dans son livre *Adaptation in Natural and Artificial Systems* (Goldberg, 1989; Holland, 1992). Ils sont, peut-être, les techniques les plus populaires dans les recherches de calcul évolutionnaire (Sivanandam and Deepa, 2008).

Au cours des dernières années, la communauté des algorithmes génétiques a transformé une grande partie de son attention sur les problèmes d'optimisation dans l'ingénierie industrielle, ce qui entraîne un nouveau domaine de la recherche et des applications (Gen and Cheng, 1999; Sahab et al., 2005)

Ces applications concernent principalement, l'optimisation de fonctions numériques très compliquées, le traitement d'image, le contrôle de systèmes industriels, l'apprentissage des réseaux de neurones...etc.

1.3.1 Terminologie basique des algorithmes génétiques

Avant de commencer une discussion sur les Algorithmes génétiques, il est essentiel de connaître la terminologie de base qui sera utilisée tout au long de ce chapitre (Figure 1.2).

- **Population** : C'est un sous-ensemble de toutes les solutions possibles (encodées) au problème donné ;
- **chromosomes** : une représentation d'une solution ;
- **gène** : une position d'élément d'un chromosome ;
- **allèle** : C'est la valeur qu'un gène prend pour un chromosome particulier ;
- **génotype** : Le génotype est la population dans l'espace de calcul. Dans l'espace de calcul, les solutions sont représentées d'une manière qui peut être facilement comprise et manipulée à l'aide d'un système informatique ;
- **phénotype** : le phénotype est la population dans l'espace réel de la réalité dans le monde où les solutions sont représentées d'une manière telle qu'elles sont représentées dans des situations réelles.

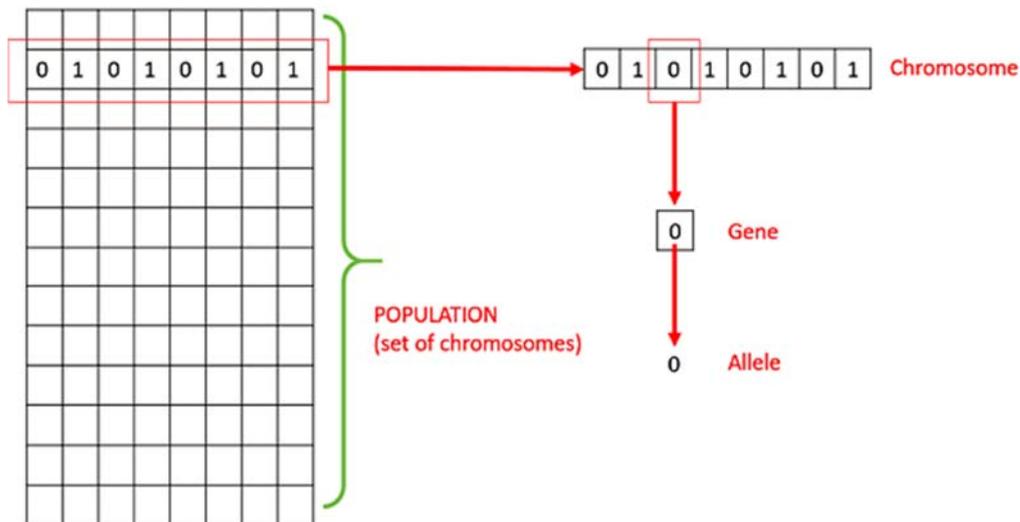


Figure 1.2 – Terminologie basique des AGs (<https://www.tutorialspoint.com/genetic...>)

1.3.2 Principe de base

Généralement, le principe de ces techniques repose sur l'évolution d'une population de solutions qui sous l'action de règles précises optimisent un comportement donné, exprimé sous forme d'une fonction, dite *fonction sélective (fitness function)* ou *adaptation à l'environnement* (Lutton, 1999)

Un algorithme génétique gère une population de solutions potentielle possibles dite « **population initiale** ». Chaque solution est représentée par un chromosome, qui est juste une représentation abstraite. Toutes les solutions possibles sont codées dans un chromosome qui est la première étape, l'étape suivante consiste à mesurer la faculté de fitness définie par l'utilisateur. Selon le critère de la sélection naturelle les meilleurs chromosomes ont plus de chance d'être sélectionnés pour la reproduction, la population ou la génération suivante hérite de leur matériel génétique.

Un ensemble d'opérateurs génétiques de reproduction doit être déterminé et appliqué directement sur les chromosomes, et sont utilisés pour effectuer des mutations et des croisements pour plus de solutions du problème. Après plusieurs générations, l'algorithme converge vers le meilleur individu, qui représente une solution optimale au problème (Gen and Cheng, 1999; Steeb, 2008).

1.3.3 Fonctionnement d'un algorithme génétique

En général, un algorithme génétique a cinq éléments fondamentaux tels que résumés par Michalewicz ([Gen and Cheng, 1999](#)):

1. Une représentation génétique avec un algorithme de la solution du problème (représentation chromosomique) ;
2. une méthode de créer une population initiale de solution ;
3. une solution de la fonction d'évaluation en fonction de la performance ;
4. l'introduction des opérateurs d'algorithmes génétiques qui modifient la composition génétique des enfants (les solutions) lors de la reproduction ;
5. les valeurs des paramètres des algorithmes génétiques.

A partir de ces définitions, les étapes du fonctionnement d'un algorithme génétique sont les suivantes (Figure 1.3) ([Chang et al., 2012](#)):

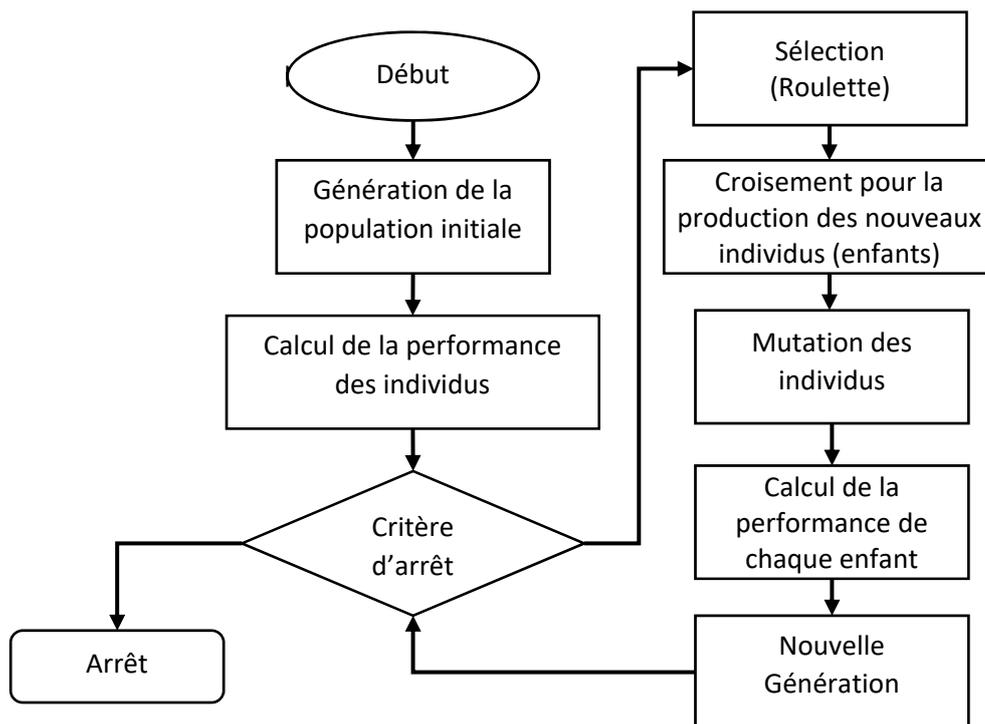


Figure 1.3 – Processus d'un algorithme génétique ([Kang et al., 2011](#)).

1. Encoder le problème dans une chaîne et générer la première population en utilisant la procédure d'initialisation ;
2. Calculer de la valeur de la performance de chaque chromosome ;

3. Reproduire des chromosomes (enfant) jusqu'à ce atteindre le critère d'arrêt soit ; la reproduction se compose d'itérations des étapes suivantes ;
 - ✚ Choix d'un certain nombre de parents à reproduire ; la sélection est stochastique, mais les personnes ayant les plus hautes évaluations sont favorisées dans la sélection.
 - ✚ Application des opérateurs des algorithmes génétiques (croisement, mutation).
 - ✚ Evaluation de la meilleure performance des meilleurs enfants (solution), et on les remplace par les mauvais individus de la population.

1.3.4 Codage d'un individu

Pour tout algorithme génétique, une représentation sous forme d'un chromosome est nécessaire pour décrire chaque individu dans la population. Le schéma de représentation détermine comment le problème est structuré dans l'AG et donne également les opérateurs génétiques qu'on doit utiliser. Chaque individu ou chromosome est constitué d'une séquence de gènes d'un certain alphabet ([Sivanandam and Deepa, 2008](#)).

La façon d'encoder une solution d'un problème donné dans un chromosome est un problème clé pour l'AG. Ce problème a été étudié à partir de nombreux aspects, tels que la cartographie des caractères d'un espace de génotype vers un espace de phénotype lorsque les individus sont décodés en solutions et les propriétés de l'évolution lorsque les individus sont manipulés par des opérateurs génétiques.

Diverses méthodes de codage (Figures 1.4 et 1.5) ont été créées pour des problèmes particuliers afin d'avoir une mise en œuvre efficace de l'AG. Selon les types de symboles utilisés comme allèles d'un gène, les méthodes de codage peuvent être classées comme suit :

- encodage binaire ;
- encodage réel ;
- encodage de permutation entière / littérale ;
- un encodage général de la structure des données.

L'encodage du nombre réel est meilleur pour les problèmes d'optimisation des fonctions. Il a été largement confirmé que l'encodage du nombre réel avait des performances supérieures à celles du codage binaire. ([Gen et al., 2008](#)).

0	1	1	0	0	1	1
---	---	---	---	---	---	---

Figure 1.4 – Codage d'un individu par chaîne binaire.

1	2	0.5	20	-7	9	11
---	---	-----	----	----	---	----

Figure 1.5 – Codage d'un individu par chaîne de bits réels

1.3.5 Génération de la population initiale

La population initiale peut être soit un échantillon aléatoire de l'espace de solution, soit être semée avec des solutions trouvées par des procédures de calcul de recherche locales simples. Les résultats du processus tendent à trouver des solutions avec une erreur optimale globale (Azzini, 2005).

1.3.6 Fonction de fitness ou d'évaluation

La fonction objective est employée pour fournir une mesure de la façon dont les individus sont exécutés dans le domaine du problème. Dans le cas d'un problème de minimisation, les individus les plus adaptées auront la valeur numérique la plus basse de la fonction objective associée. Cette mesure brute de la fitness des individus n'est généralement utilisée que comme étape intermédiaire pour déterminer la performance relative des individus dans un algorithme génétique, ou la fonction de fitness (Eq. 1.2), est normalement utilisée pour transformer la valeur de la fonction objective (Eq. 1.1) en une mesure de la performance relative de chaque individu comme précisé par (Chipperfield et al, 2005).

$$F(x) = g(f(x)) \quad (1.1)$$

Où f est la fonction objective, g la fonction objective en un nombre non négatif et F est la fonction fitness relative.

La fitness de chaque individu, $F(x_i)$ est calculée comme la performance de l'individu $f(x_i)$ par rapport à l'ensemble de la population

$$F(x_i) = \frac{f(x_i)}{\sum_{i=1}^{N_{ind}} f(x_i)} \quad (1.2)$$

Avec : N_{ind} est la taille de la population et x_i la valeur phénotypique (réel) de l'individu.

Dans l'algorithme génétique, la fonction de performance permettra d'évaluer l'adaptation de chaque individu et de décider si le résultat est bon ou non. L'opérateur de

sélection choisira les parents adoptifs en fonction de leurs valeurs de fitness. Par cette étape, la population tend vers de meilleurs individus (Goldberg, 1989)

1.3.7 Opérateurs des algorithmes génétiques

Un AG est un algorithme itératif de recherche d'optimum. La génération d'une nouvelle population telle qu'elle est représentée par la fonction objective se fait par application des opérateurs génétiques : la *sélection*, le *croisement* et la *mutation*.

1.3.7.1 La Sélection

Dans ce processus itératif, les individus sont sélectionnés de la population courante selon la stratégie de sélection prédéfinie. Il existe plusieurs schémas de sélection. La plupart d'entre eux se base sur les valeurs de la fitness des individus telles que la Rouettes biaisée (Figure 1.6), la sélection par tournoi (Figure 1.7), etc... Généralement, ces stratégies assurent une probabilité de sélection supérieure des individus avec des valeurs de fitness optimales. Une telle sélection tend à augmenter l'importance des bonnes solutions par rapport aux mauvaises solutions (Steeb et al., 2005).

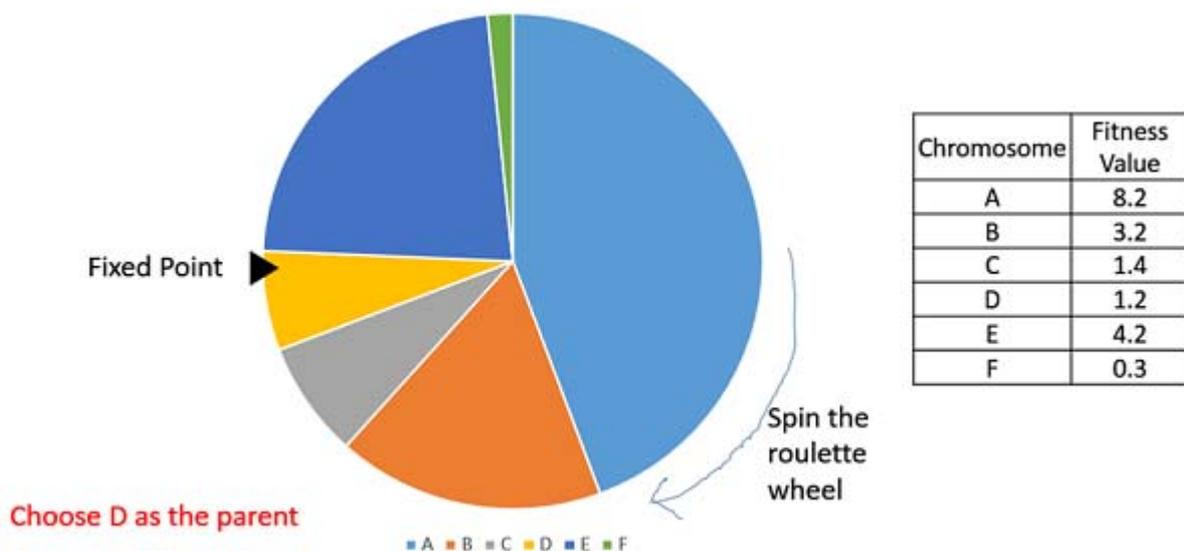


Figure 1.6 – Exemple de sélection par Rouettes biaisé
(<https://www.tutorialspoint.com/genetic...>)

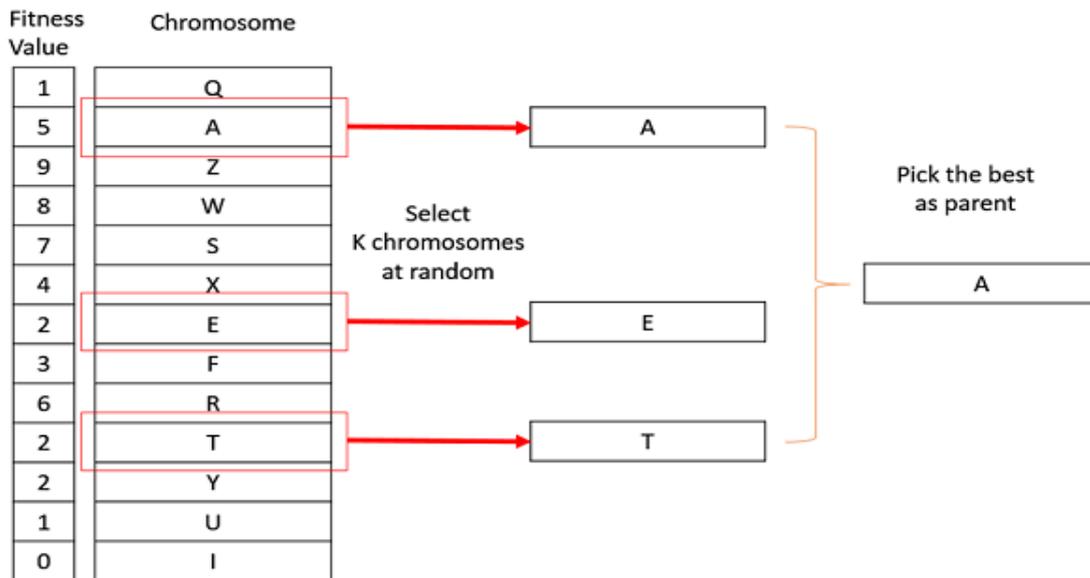


Figure 1.7 – Exemple de sélection type Tournement (<https://www.tutorialspoint.com/genetic..>)

1.3.7.2 Croisement

L'opération de croisement (Figure 1.8) consiste à sélectionner deux individus à partir des individus existants et de générer un nouveau meilleur individu à travers l'échange et la combinaison de deux chromosomes. Le processus de transition est de choisir deux chromosomes des groupes et avec sélection aléatoire d'un point ou plusieurs points à échanger (Jiang, 2013)

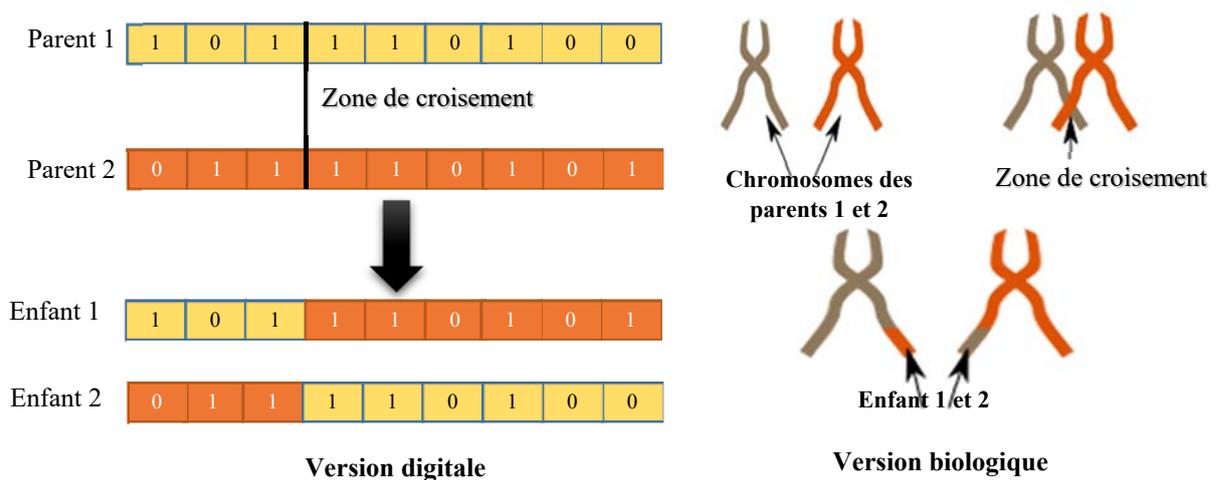


Figure 1.8 – Opérateurs basiques des algorithmes génétiques (croisement) (Rebouh et al. 2017).

1.3.7.3 Mutation

La mutation est définie comme étant l'inversion d'un bit dans un chromosome (Figure 1.9). Cela revient à modifier aléatoirement la valeur d'un paramètre du dispositif. Les mutations jouent le rôle de bruit et empêchent l'évolution de se figer. Elles permettent d'assurer une recherche aussi bien globale que locale, selon le poids et le nombre des bits mutés. De plus, elles garantissent mathématiquement que l'optimum global peut être atteint.

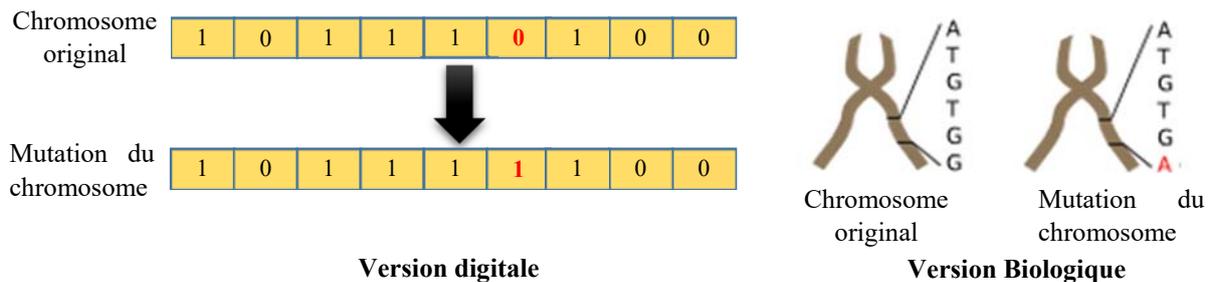


Figure 1.9 – Opérateurs basiques des algorithmes génétiques (Mutation) (Rebouh et al. 2017).

1.3.8 Avantages majeurs des algorithmes génétiques

Il existe trois avantages majeurs lors de l'application d'un AG aux problèmes d'optimisation (Gen et al., 2008) :

- **Adaptabilité** : l'AG n'a pas beaucoup d'exigences mathématiques concernant les problèmes d'optimisation. En raison de la propriété évolutive, AG cherchera des solutions sans prendre en considération le fonctionnement interne spécifique du problème. L'AG peut gérer n'importe quel type de fonctions objectives et tout type de contraintes, c'est-à-dire linéaire ou non linéaire, définies sur des espaces de recherche discrets, continus ou mixtes.
- **Robustesse** : l'utilisation des opérateurs d'évolution rend l'AG très efficace dans la résolution des problèmes avec la recherche globale (en probabilité), alors que la plupart des heuristiques classiques effectuent généralement une recherche locale. Il a été prouvé par de nombreuses études que l'AG est plus efficace et plus robuste pour trouver une solution optimale et réduire l'effort de calcul que d'autres méthodes heuristiques conventionnelles.
- **Flexibilité** : l'AG offre une grande flexibilité pour s'hybrider avec des méthodes heuristiques pour une mise en œuvre efficace pour un problème spécifique.

1.4 Réseaux de neurones artificiels

Les réseaux de neurones formels sont devenus en quelques années des outils précieux dans des domaines très divers de l'industrie et des services (Koehn, 1994). Les Réseaux de Neurones Artificiels (RNAs) sont considérés parmi les métaphores biologiques employées de nos jours pour la résolution des problèmes (Dreyfus, 2002). Ils sont à l'origine une tentative de modélisation mathématique du fonctionnement du cerveau humain. Plusieurs auteurs se sont intéressés aux RNAs et chacun les a définis à sa manière. Un RN est un système composé d'un ensemble de neurones interconnectés entre eux. Le RN Multicouches à Rétro-Propagation (RNM-RP) est le modèle le plus utilisé (Boukhatem et al., 2010)

Ces dernières années, les réseaux de neurones artificiels (RNAs) ont montré des performances exceptionnelles comme des outils de régression, en particulier lorsqu'ils sont utilisés pour la reconnaissance des formes et l'estimation des fonctions. Ils sont fortement non linéaires, et peuvent traiter les interactions complexes des variables d'entrée-sortie dans un système sans aucune connaissance préalable sur la nature de ces interactions, Le principal avantage des réseaux de neurones est qu'on ne doit pas explicitement assumer une forme modèle, qui est une condition préalable à l'approche paramétrique (Ji et al., 2006).

1.4.1 Théorie et définitions des Réseaux de Neurones Artificiels

Les réseaux de neurones artificiels sont des ensembles de neurones formels associés en couches fonctionnant en parallèle. Chaque neurone (processeur élémentaire) calcule une sortie unique sur la base des informations qu'il reçoit. Dans un réseau, chaque sous-groupe fait un traitement indépendant des autres et transmet le résultat de son analyse au sous-groupe suivant. L'information donnée au réseau va donc se propager couche par couche, de la couche d'entrée à la couche de sortie, en passant soit par aucune, une ou plusieurs couches intermédiaires (dites couches cachées). Les réseaux de neurones ont la capacité de stocker de la connaissance dans les poids synaptiques, obtenus par des processus d'adaptation ou d'apprentissage et de la rendre disponible à l'usage (Mordjaoui, 2008). Le nombre de neurones dans les couches est choisi pour être suffisant afin d'obtenir la précision souhaitée dans la résolution du problème, le nombre de couches est désiré pour être minimal pour diminuer le temps de résolution. Un réseau de neurones représente un système dynamique hautement parallèle avec une topologie graphique dirigée qui peut traiter les informations au moyen d'une réaction de son état sur les actions d'entrée. (Galushkin, 2007)

Un réseau de neurones est un processeur massivement distribué en parallèle qui a une propension naturelle pour stocker de la connaissance empirique et la rendre disponible à l'usage. Il ressemble au cerveau sur deux aspects (Haykin, 1994) :

- la connaissance est acquise par le réseau au travers d'un processus d'apprentissage ;
- les connexions entre les neurones, connues sous le nom de poids synaptiques servent à stocker la connaissance.

1.4.2 Neurone artificiel (formel)

Un neurone réalise simplement une fonction non linéaire, paramétrée, de ses variables. L'intérêt des neurones réside dans les propriétés qui résultent de leur association en réseaux, c'est-à-dire de la composition des fonctions non linéaires réalisées par chacun des neurones (Dreyfus, 2004)

Le premier modèle de réseau des neurones est présenté par McCulloch et Pitts en 1943 (voir Yang et al., 2003) qui ont défini le cerveau humain comme un ordinateur bien structuré s'est composé d'infinité de neurones.

Le neurone formel est une modélisation mathématique qui reprend les principes du fonctionnement du neurone biologique. Un neurone est une fonction algébrique non linéaire, paramétrée, à valeurs bornées (Dreyfus, 2002). D'un point de vue mathématique (Figure 1.10), le neurone formel peut être représenté de la manière suivante :

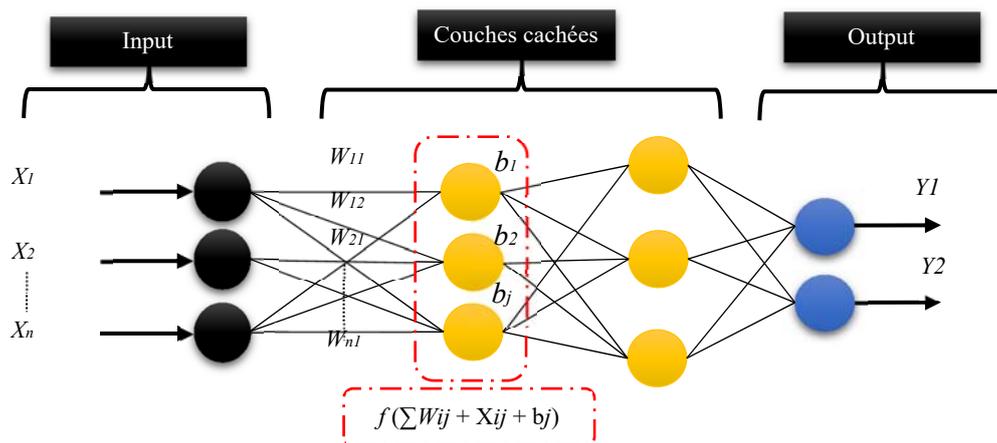


Figure 1.10 – Modélisation simplifiée du neurone biologique (Mac Culloch et Pitts)

Le neurone formel est donc une modélisation mathématique qui reprend les principes du fonctionnement du neurone biologique, en particulier la sommation des entrées.

1.4.3 Concepts de base

Le RN est entraîné en lui présentant un ensemble de données entrées-sorties associées basées sur une règle d'apprentissage. Le processus d'apprentissage utilise un algorithme, au cours duquel le RN développe une fonction entre les entrées et les sorties. Généralement, dans un processus d'apprentissage, les neurones reçoivent les données d'entrée (x_1, \dots, x_n) et les transmettent aux neurones dans la couche cachée, qui sont responsables de simples calculs mathématiques utiles impliquant les poids de connexions (w_{11}, \dots, w_{1n}) , les biais (b_1, \dots, b_n) , et les valeurs d'entrée.

Le résultat de ces neurones est passé par une fonction d'activation (f) à chaque neurone qui limite la sortie avec les bornes minimales et maximales permises. Le choix du type de cette fonction se révèle être un élément très important d'un RN et souvent des fonctions non linéaires seront nécessaires. Une fois cette fonction appliquée, les résultats finaux sont produits. Par la suite, ces résultats deviennent les entrées à tous les neurones dans la couche adjacente, et le processus de calcul est répété par le biais des couches jusqu'à la couche de sortie, les valeurs de sortie sont produites aux neurones de sortie (y_1, y_2) . À ce stade, une valeur d'erreur de sortie est calculée entre les sorties produites et les sorties désirées.

Généralement, le processus d'apprentissage est itératif, et s'arrête quand un écart acceptable est atteint. À l'achèvement du processus d'apprentissage, le réseau devrait être en mesure de donner la solution de sortie pour tout ensemble de données sur la base de l'architecture généralisée développée (Boukhatem et al., 2010).

Le réseau neurone se divise en trois parties : couche d'entrée, Une ou plusieurs couches cachées et couche de sortie, dont l'activation de ces neurones est interprétée comme étant la réponse du réseau. Pour un nombre compris entre $j = 1$ et un nombre n , le neurone formel va calculer la somme de ses entrées (x_1, \dots, x_n) , pondérées par des poids synaptiques (w_1, \dots, w_n) , et la comparer avec un seuil teta (θ) . D'où la formule avec la fonction de transfert (f) .

$$y = f(\text{net}) \quad (1.3)$$

$$\text{net} = \sum_i W_i x_i + \theta \quad (1.4)$$

Où : y , x_i sont les variables sortie, les variables entré respectivement, θ est le biais ou le seuil d'activation de neurone, W_i le poids synaptique du neurone i d'une couche d'entrée.

Il existe plusieurs types de fonction d'activation. Généralement trois fonctions sont les plus utilisées les fonctions «seuil», «linéaire» et «sigmoïde» (Figure 1.11) (Parizeau, 2003).

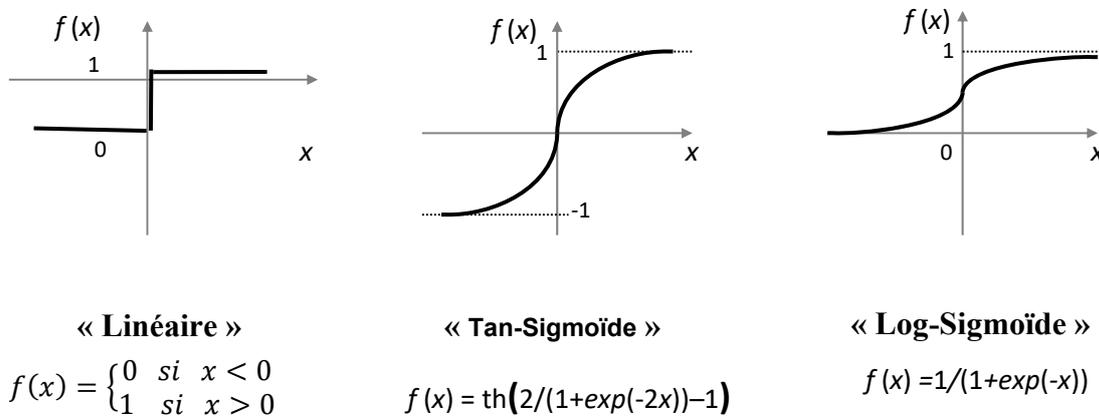


Figure 1.11– Type de fonctions d'activation.

1.4.4 Réseaux de neurones non boucle (ou statique) "FEED-FORWARD"

Appelés aussi "réseaux de type Perceptron", ce sont des réseaux dans lesquels le flux d'information se propage de couche entrée vers couche cachés jusqu'à la sortie sans retour en arrière. Un réseau de neurone non bouclé réalise une ou plusieurs fonctions de ses entrées par composition des fonctions réalisées par chacun des neurones (Dreyfus, 2002).

Un réseau de neurone est un système composé d'un ensemble de neurones interconnectés les uns avec les autres. Une certaine disposition de la connexion de ces neurones a produit un modèle de réseau neuronal adapté à certaines tâches. Le Perceptron multicouches à rétropropagation (**Back Propagation Multilayer Perceptron** « **BPMLP** ») est le modèle de réseau neurone le plus utilisé, composé de trois couches adjacentes, entrées, cachées et sorties où chaque couche contient plusieurs neurones (Boukhatem et al., 2012).

Le Perceptron multicouches est un réseau de neurones qui a plus d'une couche cachée entre la couche d'entrée et de couche de sortie, chaque couche contient des unités de calcul (neurones) connectées à d'autre neurones par des poids (Rumelhart et al., 1986; Yang et al., 2003). Il s'agit d'une version simple de réseau de neurones largement utilisé en l'ingénierie (Figure 1.12).

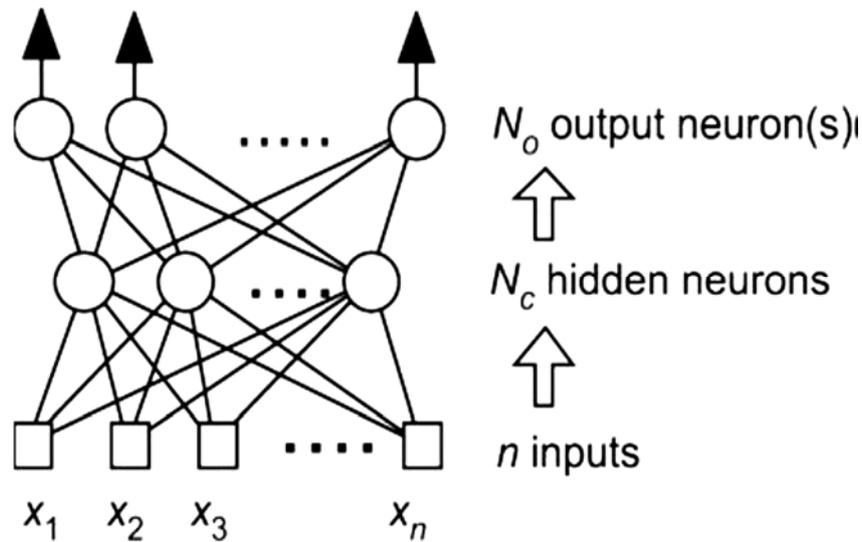


Figure 1.12 – Perceptron Multicouches.

Un perceptron multicouche composé de trois couches est représenté par les équations suivantes :

$$y_i = f(\text{net}_j) \quad (1.5)$$

$$\text{net}_j = \sum_i W_{ji} x_i + \theta_j \quad (1.6)$$

Où : x_i est la valeur de 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.

Les équations (2.3) et (2.4) sont les opérations de la couche de sortie, Ils utilisent les y_i ; la valeur de sortie de la couche cachée.

$$z_k = f(\text{net}_k) \quad (1.7)$$

$$\text{net}_k = \sum_k W_{kj} x_j + \theta_k \quad (1.8)$$

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 » est la différence entre la valeur de sortie calculée Z_k et la valeur de sortie désirée d_k .

$$E = \frac{1}{2} \sum_k (d_k - Z_k)^2 \quad (1.9)$$

La performance d'un BPMLP dépend fortement de sa capacité de généralisation, qui est attachée à la représentation des données. Une caractéristique importante de la représentation des données est la dé-corrélation de ces données. En d'autres termes, un ensemble de données présentées à un BPMLP ne devrait pas consister en des corrélations entre-elles car les données corrélées réduisent le caractère distinctif de la représentation des

données et, par conséquent, introduisent une confusion sur le modèle pendant le processus d'apprentissage et, par conséquent, BPMLP avec une faible capacité de généralisation pour de nouvelles données (Boukhatem et al., 2012).

1.4.5 Apprentissage d'un réseau de neurones

La notion d'apprentissage claire et intuitive pour les humains ou les animaux est une procédure cognitive qui doit faire en sorte que l'individu réalise de manière autonome une tâche donnée. 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 (Dreyfus, 2002).

L'apprentissage est vraisemblablement la propriété la plus intéressante des réseaux de neurones. L'apprentissage est un processus dynamique et itératif permettant de modifier les paramètres d'un réseau en réaction avec les entrées (Mordjaoui, 2008).

Malheureusement, il n'existe pas de définition générale, universellement acceptée, car ce concept touche à trop de notions distinctes qui dépendent du point de vue que l'on adopte.

- On appelle « apprentissage » des réseaux de neurones la procédure qui consiste à estimer les paramètres des neurones du réseau, afin que celui-ci remplisse au mieux la tâche qui lui est affectée (Dreyfus, 2002).
- L'apprentissage est un processus dynamique et itératif permettant de modifier les paramètres d'un réseau en réaction avec les stimuli qu'il reçoit de son environnement.

Le type d'apprentissage est déterminé par la manière dont les changements de paramètre surviennent (Parizeau, 2004).

1.4.5.1 Principe de l'algorithme d'apprentissage

Il y a plusieurs algorithmes d'apprentissage pour RNA, le plus utilisé est l'algorithme de rétropropagation. Le signal d'apprentissage est transmis de la couche de sortie vers la couche caché en suite le signal se retourne à la couche sortie, le processus est répété d'une manière itérative jusqu'à obtention l'erreur désiré (Yang et al., 2003).

Les étapes de l'algorithme de Rétropropagation sont :

-Etape 01 : initialisation des paramètres principales ; les poids (W_{kj} , W_{ij}), les biais (θ_k , θ_j), le taux d'apprentissage (η) et le momentum (α)

-Etape 02 : calcul de l'erreur généralisée δ_k

$$\delta_k = Z_k (1 - Z_k)(d_k - Z_k) \quad (1.10)$$

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

$$\Delta W_{kj}(K+1) = \eta \delta_k y_j + \alpha W_{kj}(k) \quad (1.11)$$

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

$$\delta_j = y_j (1 - y_j) + \sum_k \delta_k W_{kj} \quad (1.12)$$

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

$$\Delta W_{ji}(K+1) = \eta \delta_j y_i + \alpha W_{ji}(k) \quad (1.13)$$

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

1.4.5.2 Différents types d'apprentissage

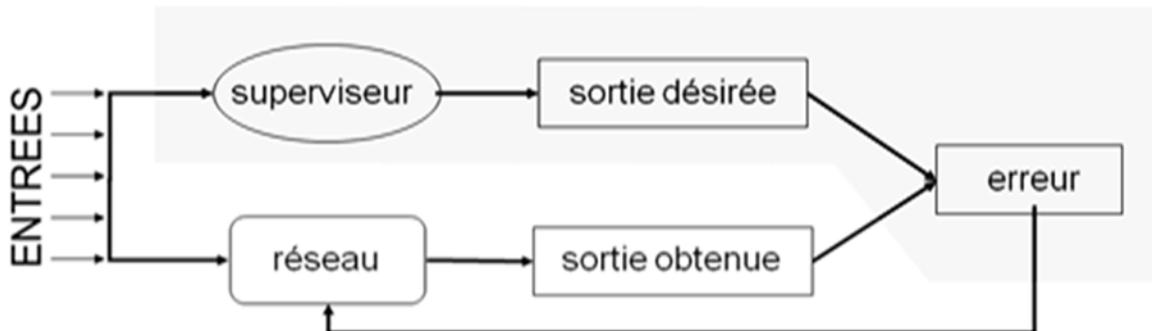


Figure 1.13 – Apprentissage supervisé (Dreyfus, 2002).

- **Apprentissage non-supervisé (ou auto-organisationnel)**

Dans ce cas, on fournit seulement les entrées (Figure 2.12). Le réseau va détecter automatiquement les régularités des entrées, les poids de connexions sont ajustés automatiquement en attribuant et en optimisant une valeur de qualité.

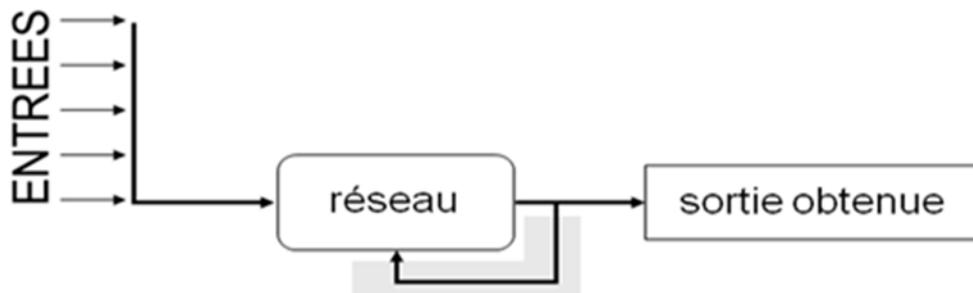


Figure 1.14 – Apprentissage non-supervisé (Dreyfus, 2002).

1.4.6 Avantage et limites des réseaux de neurones

Comme chaque technique, les RNAs ont des avantages et des inconvénients ou à vrai dire des limites :

➤ Les Avantages

- Aptitude à modéliser des structures complexes et des données irrégulières ;
- apprentissage automatique des poids de connexion ;
- **tolérance de pannes** : le dysfonctionnement d'une faible proportion des neurones n'affecte pas profondément le fonctionnement général ;
- **robustesse** : Les couches cachées du réseau forment une représentation abstraite des données (concepts), qui permettent de savoir catégoriser des données non traitées lors de l'apprentissage (non prévues) ;
- prise en compte des relations non linéaires (interactions) entre les variables ;
- assez bonne résistance aux données bruitées ;
- **parallélisme** : les RNAs sont par essence des « machines parallèles » et peuvent donc bénéficier directement des architectures multi-processeurs (tous les neurones d'un même niveau sont indépendants) ;
- **technique à découvrir les règles** : le fonctionnement des RN implique qu'ils identifient les relations entre les données soumises. On peut envisager qu'ils découvrent empiriquement des lois gouvernant les domaines traités ;
- aptitude à modéliser des problèmes très variés.

➤ Les limites

- L'apprentissage par rétropropagation des erreurs peut converger vers une solution sous-optimale (minima-locaux) ou la convergence vers la meilleure solution globale pas toujours assurée (Figure 1.15).
- problème du sur apprentissage : lorsque l'apprentissage est trop prolongé, le RN perd son pouvoir de généralisation. Il reconnaît les données de l'échantillon d'apprentissage, mais pas de nouvelles données « similaires » ;
- paramètres difficiles à interpréter (boîte noire), résultats totalement non explicites ;
- sensibilité à un trop grand nombre de variables non discriminantes ;

- détermination de l'architecture du réseau est complexe (paramètres nombreux et délicats à régler, nombre et tailles des couches cachées, taux d'apprentissage, moment...).

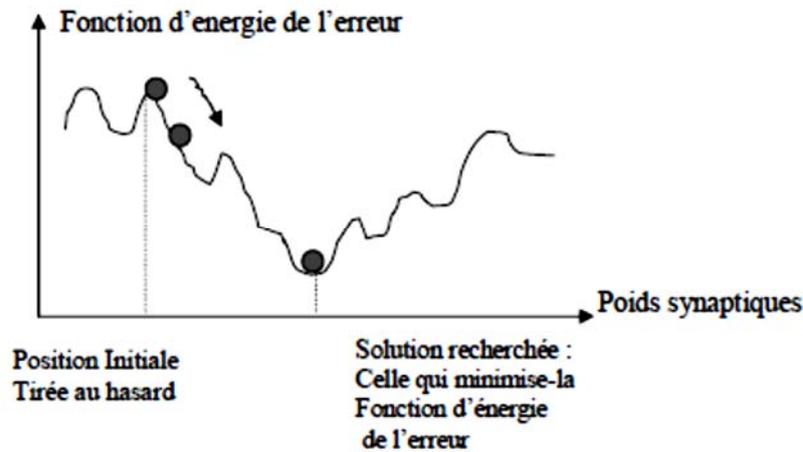


Figure 1.15 – Problème des minima locaux

La surface d'erreur d'un réseau complexe comporte beaucoup de maxima, minima, et vallées. Ce qui fait que l'algorithme du gradient peut converger vers un minimum qui n'est pas l'optimum global. Pour résoudre ce problème, on peut utiliser des méthodes probabilistes (comme les algorithmes génétiques).

1.5 Théorie de logique floue

De nos jours, la logique floue (fuzzy logic) est un axe de recherche important sur lequel se focalisent de nombreux scientifiques. Des retombées technologiques sont d'ores et déjà disponibles, tant dans le domaine grand public (appareils photos, machines à laver, fours à micro-onde), que dans le domaine industriel (classification, aide à la décision, réglage et commande de processus, complexes liés à l'énergie, aux transports, à la transformation de la matière, à la robotique, aux machines-outils).

1.5.1 Définition de la logique floue

La logique floue est une extension de la logique booléenne créée par Lotfi Zadeh en 1965 en se basant sur sa théorie mathématique des ensembles flous, qui est une généralisation de la théorie des ensembles classiques. En introduisant la notion de degré dans la vérification d'une condition, permettant ainsi à une condition d'être dans un autre état que vrai ou faux, la logique floue confère une flexibilité très appréciable

aux raisonnements qui l'utilisent, ce qui rend possible la prise en compte des imprécisions et des incertitudes.

La logique floue repose sur la théorie des ensembles flous, qui sont une généralisation de la théorie des ensembles classiques (Dernoncourt, 2011). Par abus de langage, suivant la littérature, nous utiliserons indifféremment les termes sous-ensembles flous et ensembles flous. Les ensembles classiques sont également un appel à des ensembles nets, par opposition à flou, et de même la logique classique est également appelée logique booléenne ou binaire

La figure 1.16 montre graphiquement la différence entre un ensemble classique et l'ensemble flou.

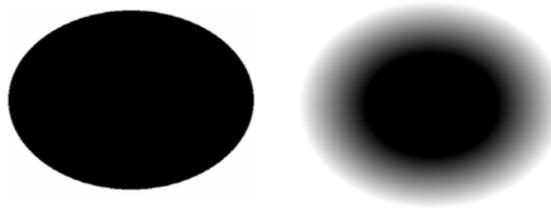


Figure 1.16 – Représentation graphique d'un ensemble classique et d'un ensemble flou (Dernoncourt, 2011)

Un des intérêts de la logique floue pour formaliser le raisonnement humain est que les règles sont énoncées en langage naturel. Voici par exemple quelques règles de Conduite qu'un conducteur suit, en supposant qu'il tienne à son permis :

Tableau 1.1 Exemple d'illustration logique floue.

Si le feu est rouge...	Si ma vitesse est élevée	Et si le feu est proche	Alors je freine fort
Si le feu est rouge...	Si ma vitesse est faible	Et si le feu est loin	Alors je maintiens ma vitesse
Si le feu est orange...	Si ma vitesse est moyenne	Et si le feu est loin	Alors je freine doucement
Si le feu est vert...	Si ma vitesse est faible	Et si le feu est proche	Alors je freine j'accélère

1.5.2 Avantage et limites de la logique floue

Il y a donc un avantage certain à travailler avec la logique floue. Cette méthode est très utile lorsque l'on se trouve confronté à des systèmes qui ne sont pas, ou difficilement modélisable.

De même, cette méthode est très avantageuse si l'on possède un bon niveau d'expertise humaine. En effet, il faut fournir au système flou toute une base de règle exprimé en langage naturel pour permettre de raisonner et de tirer des conclusions. Plus l'expertise humaine d'un système est importante et plus on est capable d'ajouter des règles d'inférences au système.

La logique floue permet donc de contrôler des systèmes complexes non forcément modélisable de façon "intuitive". Néanmoins, cette méthode présente divers inconvénients. Tout d'abord, le fait d'exprimer ses connaissances sous la forme de règles en langage naturel (et donc qualitative) ne permet pas de prouver que le système aura un comportement optimal. Tous les réglages que le programmeur doit entrer au système se fait de façon totalement ad-hoc. Cette méthode ne peut donc pas garantir que le système soit stable, précis ou optimal, ni même qu'elle ne peut garantir que les règles entrées par le programmeur ne soient pas contradictoire

1.6 System hybride algorithmes génétiques et réseaux de neurones « RNAG »

L'idée de combiner AG et RN est apparue à la fin des années 80, elle a engendré un champ de recherche intense dans les années 1980. Puisque les deux sont des méthodes informatiques autonomes. En bref, le problème avec les réseaux neuronaux est qu'un certain nombre de paramètres doivent être définis avant de commencer le processus d'apprentissage. Cependant, il n'existe pas de règles claires sur la façon de définir ces paramètres En combinant des algorithmes génétiques avec des réseaux neuronaux (RNAG), l'algorithme génétique est utilisé pour trouver ces paramètres. L'inspiration de cette idée vient de la nature : dans la vie réelle, le succès d'un individu n'est pas seulement déterminé par ses connaissances et ses compétences, qu'il a acquises grâce à l'expérience (l'apprentissage du réseau neuronal), elle dépend aussi de son héritage génétique (mis en place par l'algorithme génétique). (Koehn, 1994).

La méthode d'apprentissage généralement utilisé dans les réseaux de neurones à rétropropagation (BP) est l'ajustement du poids basé sur la descente en gradient, comme la

rétropropagation du gradient, ainsi que les algorithmes de gradients conjugués. Cependant, un des problèmes fréquemment rencontré lors de l'apprentissage de réseaux de neurones complexes, lorsque la valeur du taux d'apprentissage et de momentum est très faible est la convergence vers des optima locaux (Yi, 2015), c.à.d. à la fin du processus d'itération, on n'obtient donc pas l'optimum global de la fonction d'erreur, mais un de ses optima locaux.

Afin d'améliorer encore cette convergence, différents approches ont été proposées par les chercheurs, parmi ces approches c'est l'apprentissage hybride. Cette approche consiste à combiner les AG et la BP, pour bénéficier des avantages combinés de chacune de ces deux méthodes.

Les algorithmes génétiques ont été utilisés conjointement aux réseaux de neurones dans 5 grandes catégories d'applications différentes :

- Les algorithmes génétiques ont été utilisés pour l'apprentissage des poids d'un réseau, pour une architecture fixée ;
- l'utilisation d'algorithmes génétiques pour trouver une bonne règle d'apprentissage ainsi que les paramètres associés ;
- les algorithmes génétiques ont également été utilisés pour **trouver l'architecture optimale d'un réseau**, incluant la recherche du nombre de neurones ainsi que les connexions optimales entre ces neurones ;
- les algorithmes génétiques ont été utilisés pour diminuer le nombre d'entrées d'un réseau de neurones, afin de garder uniquement les entrées pertinentes ;
- les algorithmes génétiques ont été utilisés pour sélectionner les meilleurs éléments des groupes d'apprentissage lors d'une phase d'apprentissage de réseau de neurones (Houssou, 2005).

1.6.1 Hybridation neuro-floue

Les réseaux de neurones sont des structures de calcul efficaces, capables d'apprendre et de s'adapter par des exemples, les systèmes flous n'étant pas puissants dans l'apprentissage, l'adaptation, et le calcul parallèle. Les réseaux de neurones offrent de bonnes performances dans ces aspects. Les réseaux de neurones manquent de flexibilité et la représentation symbolique des connaissances, alors que la logique floue en est puissante. Dans les dernières années, plusieurs recherches ont été faites pour réaliser des hybridations entre la logique floue et les réseaux de neurones, pour tirer profit des avantages de l'une et de l'autre.

L'hybridation peut être la clé pour résoudre des problèmes pratiques et complexes, nous avons fait une recherche en utilisant les mots clé « **hybrid genetic** » et « **hybrid evolutionary** », sur certaines des bases des données scientifiques populaires comme ScienceDirect, IEEE-Xplore et SpringerLink pour voir le nombre de publications.

Les résultats de la requête sont présentés dans le tableau 1.2 ci-dessous. Étant donné qu'aucun filtrage n'a été utilisé dans la requête, le nombre de documents pertinents pourrait être inférieur aux chiffres mentionnés.

Tableau 1.2 – Nombre des publications qui contiennent le mot clé « hybrid genetic et hybrid evolutionary »

Mots-clés	ScienceDirect	IEEE-Xplore	SpringerLink
Hybrid evolutionary	52 108	2 961	72 206
Hybrid genetic	140 545	5 864	148 542

1.6.2 Comparaison entre la BP, GA et méthode hybride (GA + BP)

Les deux techniques AG et les RNAs sont des stratégies de recherche générales, mais les AGs effectuent une recherche plus globale que RN a rétropropagation (BP). Une comparaison faite par Katino 1990 entre le AG, RNA et RNAG est présenté dans la Figure 1.17 (Koehn, 1994). La figure montre la convergence des différentes techniques, La rétropropagation à prend plus de temps pour atteindre le voisinage a une solution optimale, mais l'accède plus précisément. D'autre part, les algorithmes génétiques étudient l'espace de recherche entier. Par conséquent, ils atteignent plus rapidement la région des solutions optimales, mais ont des difficultés à localiser le point exact.

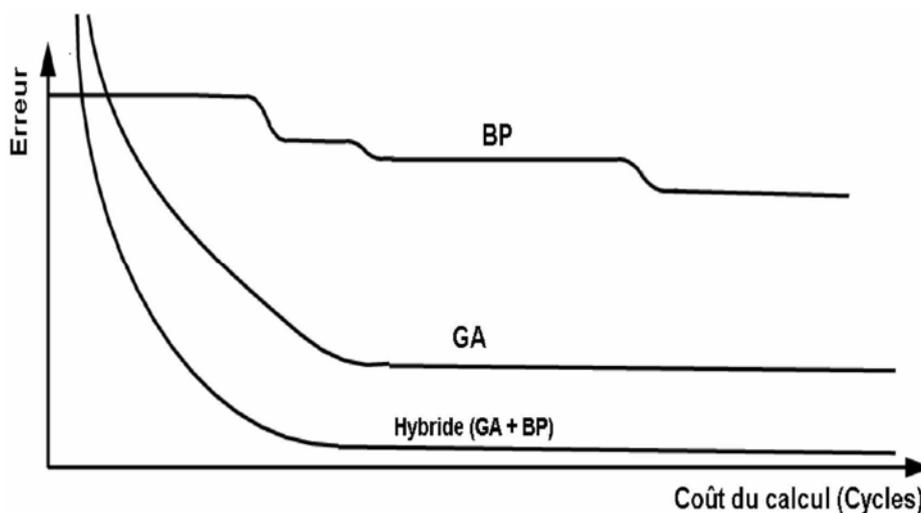


Figure 1.17 – Comparaison entre la BP, GA et GA + BP (Koehn, 1994)

L'algorithme le plus performant est l'algorithme hybride, il est meilleur que l'algorithme génétique. L'algorithme de BP converge rapidement vers un des sous optima locaux, avec le temps il peut trouver d'autre sous optima locaux, meilleurs, mais c'est rare de convergé vers un optimum global.

1.7 Conclusion

Dans ce présent chapitre, on a fait une présentation des certaines branches de l'intelligence artificielle, qui sont les algorithmes génétiques, les réseaux de neurones artificiels et la logique floue. D'après cette présentation, on constate que chaque technique à ses avantages et ses limites. A cause de cela, un nouveau système a été développé qui est le système hybride entre les différentes branches de l'intelligence artificielle on combinant les avantages de chaque technique.

L'inconvénient majeur des RNAs à rétropropagation est le problème de minima locaux qui est la convergence rapide vers un de leurs sous optima locaux, en outre l'inefficacité de converger vers un optimum global, toutefois les AGs présente une bonne recherche globale sur un ensemble de solution.

A cet effet, l'hybridation entre les AGs et les RNAs, présente des performances plus efficaces et plus rapide dans la résolution des problèmes plus complexes. Cette approche sera utilisée pour le développement du modèle de formulation de béton dans le chapitre 4.

#

CHAPITRE 02

*Application de l'intelligence Artificielle
dans la Technologie de béton.*

#

#

2.1 Introduction

L'application de l'intelligence artificielle dans le domaine du génie-civil a commencé vers la fin des années 1980. La recherche dans ce domaine a été développée depuis 1956, lorsque le terme "Intelligence Artificielle, IA" a été utilisé lors d'une réunion au Collège Dartmouth.

Ce chapitre présente un état de l'art de l'utilisation et le potentiel d'application de cette technique dans les différents domaines et les branches de génie-civil. L'objectif est donc d'assurer le développement et l'application de cette technologie à la résolution des problèmes et concevoir des solutions dans plusieurs filières telles que les structures et les constructions, la géotechnique et la technologie du béton. Dans ce dernier, ces problèmes concernent la formulation, l'ouvrabilité, la résistance à la compression et la durabilité des bétons.

2.2 Utilisation des AGs et les RNAs dans le domaine de Génie Civil

Plusieurs travaux de recherche par l'utilisation des réseaux de neurones et les algorithmes génétiques ont été effectués dans le domaine de génie-civil. Ils ont été appliqués pour : la détection des dommages structuraux, l'identification des systèmes structuraux, la modélisation du comportement des matériaux, l'optimisation des structures et la formulation des bétons...etc.

A partir des statistiques faites sur des publications (Figure 2.1) de 1995 à 2005 du JCCE (Journal of Computing in Civil engineering), il a été trouvé que ; le terme « neural » apparaissait dans le titre dans 12% de publications (Flood, 2008).

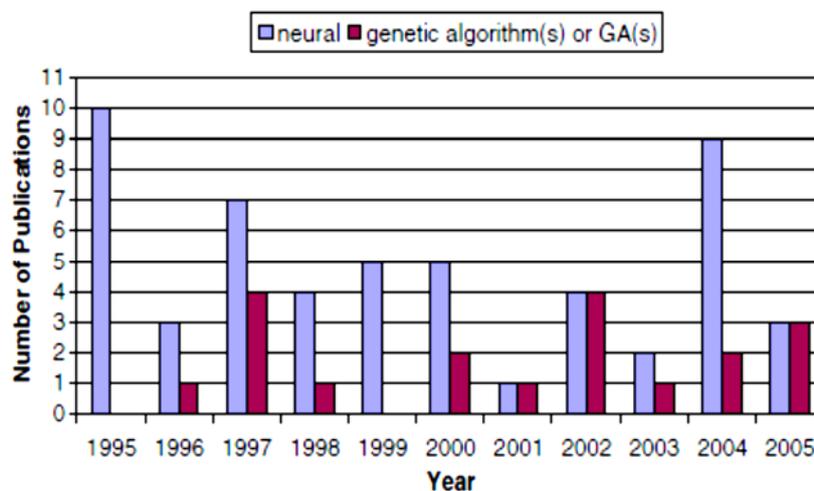


Figure 2.1– Distribution des publications par ans dans le journal JCCE (Flood, 2008).

2.3 Objectifs de la formulation d'un béton

L'évolution des connaissances du matériau, les exigences nouvelles en matière de propriétés ont incité les chercheurs et les utilisateurs à introduire dans la formulation de béton de nouveaux « produits » afin d'obtenir des propriétés appropriées.

Actuellement, les bétons ne sont plus fabriqués seulement avec des granulats, du ciment Portland et de l'eau ; ils incorporent très souvent, si ce n'est pas toujours, au moins l'un des produits suivants : adjuvants organiques, additions minérales et fibres. En plus, de la résistance en compression, les bétons doivent répondre à de nombreuses spécifications relatives aux propriétés rhéologiques, aux caractéristiques au jeune âge, aux propriétés de déformations et aux aspects de durabilité (De Larrard, 1999).

2.4 Application d'IA dans la technologie des Bétons

2.4.1 Application des algorithmes génétiques

Ces dernières années, l'amélioration des algorithmes génétiques a introduit de nombreux nouveaux outils mathématiques et la réalisation des applications intégrées au domaine de génie-civil. Avec l'évolution de l'outil informatique, les algorithmes génétiques seront plus généralisés et plus efficaces dans les applications de génie civil (Lu et al., 2012).

Plusieurs modèles ont été développés en se basant sur la méthode des algorithmes génétiques dans la technologie du béton. Sonebi et Cevic (2009) ont appliqué la programmation génétique (PG) pour modéliser et formuler le béton auto-plaçant (BAP) contenant des cendres volantes pulvérisées à partir des propriétés à l'état frais et à l'état durci en utilisant des données expérimentales . Au total, vingt-six (26) mélanges ont été faits avec un rapport eau-liant (E/L) de 0,38 à 0,72, 183–317 kg/m³ de ciment, 29–261 kg/m³ de cendres volantes et 0 à 1% de superplastifiant en masse de liant. Les paramètres des mélanges du BAP modélisés par la programmation génétique sont l'étalement, le JRing combiné à l'Orimet, le JRing combiné au cône, et la résistance à la compression à 7, 28 et 90 jours. Les résultats des modèles de programmation génétique comparés aux résultats expérimentaux pour les différentes propriétés du BAP sont présentés sur la Figure 2.2.

les coefficients de corrélation pour chaque propriété est de 0.92, 0.89, 0.72, et 0.94 pour l'étalement, l'essai de Jring-Cone , l'essai de Jring-Orimet et la résistance à la compression du BAP respectivement . Le modèle développé est capable de prédire les propriétés des mélanges du BAP conçus dans la fourchette pratique, c.à.d. dans le domaine de validité du modèle.

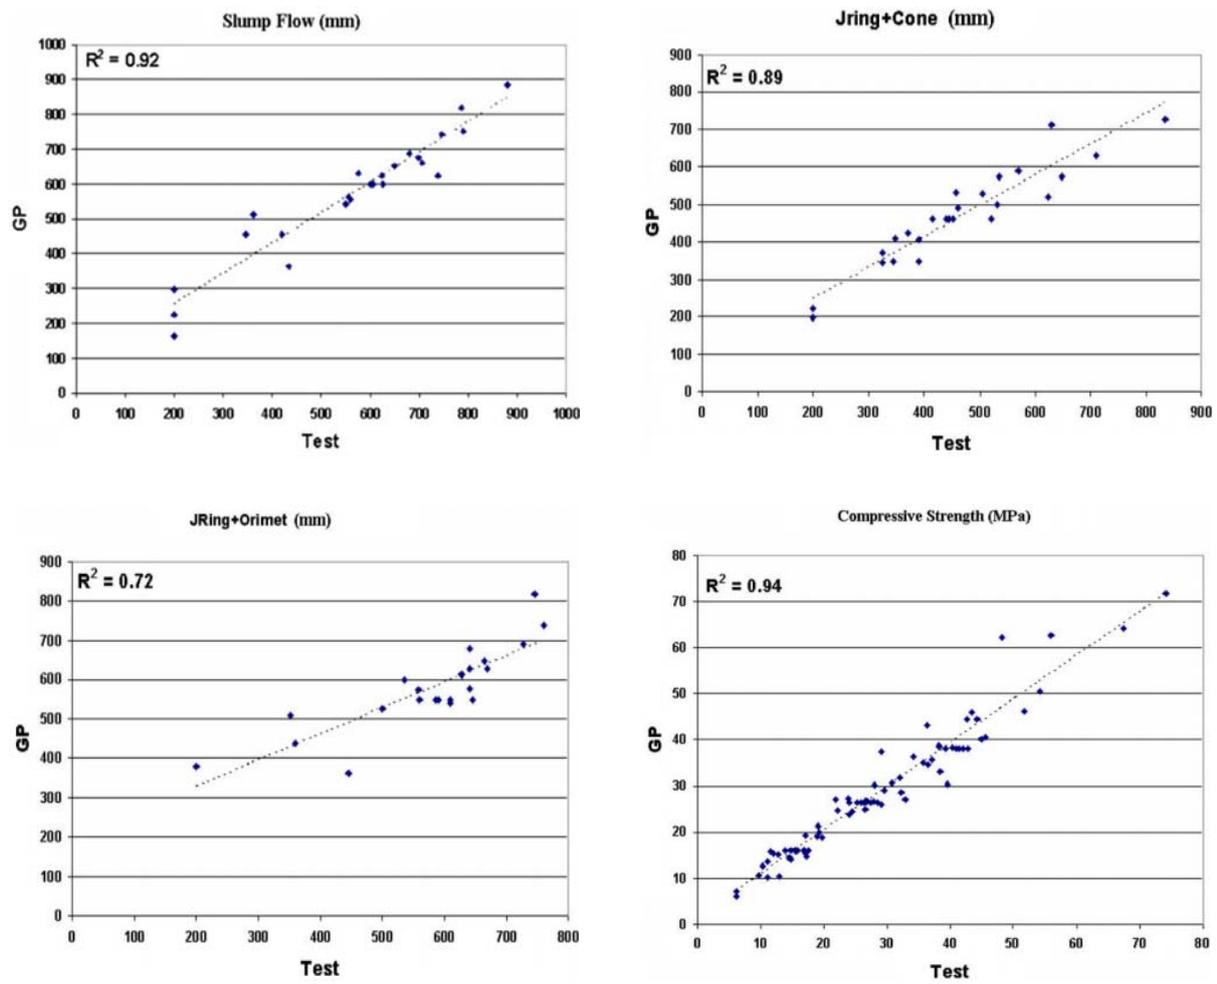


Figure 2.2 – Performance du modèle PG par rapport aux résultats des tests (Sonebi et Cevic, 2009).

La Figure 2.3 présente la résistance à la compression prédite avec les modèles basés sur la programmation génétique à 3, 7, 28 et 90 jours avec la variation de E/L, pour des dosages fixes de ciment et CV à 290 et 100 kg/m³ et SP à 0,8%. Le rapport E/L a eu un effet majeur sur la résistance à la compression et en augmentant le rapport E/L, la résistance à la compression diminue.

La Figure 2.4 montre la prédiction de la résistance à la compression avec l'utilisation de la programmation génétique « PG » en fonction de l'âge pour des mélanges réalisés avec le rapport E/L de 0,45 et SP de 0,8%. Les résultats obtenus confirment que la résistance à la compression augmente avec l'augmentation de l'âge.

De même, le dosage du ciment a été porté de 290 à 330 kg/m³, le dosage de PFA est maintenu à 100 kg/m³. On peut remarquer sur la Figure 2.4 que l'augmentation du dosage du ciment a entraîné une augmentation de la résistance à la compression à différents âges. Inversement, l'augmentation de la dose de PFA de 100 à 170 kg/m³, tandis que le dosage de ciment maintenu constant à 290 kg/m³, a conduit à une réduction de la résistance à la compression à différents âges.

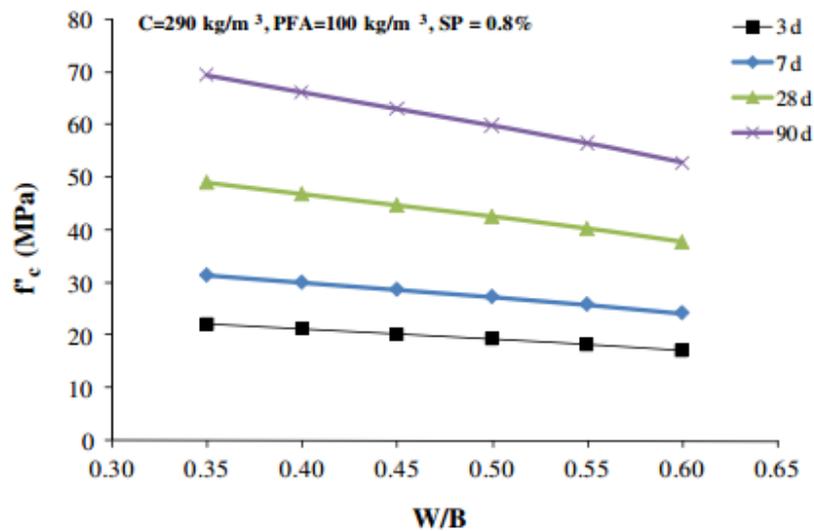


Figure 2.3 – Prédiction de la résistance à la compression du BAP en fonction de rapport E/L (Sonebi et Cevic, 2009).

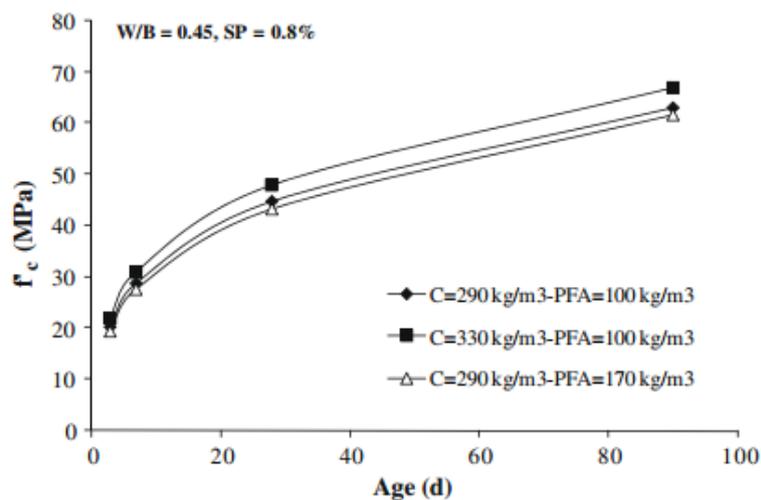


Figure 2.4 – Prédiction de la résistance à la compression en fonction d'âge. (Sonebi et Cevic, 2009).

Cette étude montre que les modèles basés sur la programmation génétique peuvent être considérés comme un moyen très pratique et peuvent être utilisés par les chercheurs.

Ozbay et al., (2008) ont utilisé la programmation génétique comme un nouvel outil pour les formulations de propriétés à l'état frais et durci du béton auto-plaçant. Pour générer une base de données pour les ensembles de formulation, un total de 44 mélanges de BAP avec et sans ajouts minéraux ont été formulés avec des rapports E/L de 0,32 et 0,44. Les ajouts minéraux utilisés étaient les cendres volantes, la fumée de silice et le laitier. Parmi les 44 mélanges de béton, les ensembles d'apprentissage et de test étaient constitués de 28 et de 16 mélanges choisis au hasard, respectivement.

Le tableau 2.1 montre que les modèles élaborés permettent la prédiction des propriétés du BAP avec une grande précision. Il est à noter, que la capacité de prédiction est plus élevée pour les propriétés à l'état durci que pour les propriétés à l'état frais.

Tableau 2.1– Paramètres statistiques de formulations basées sur les modèles élaborés (Ozbay et al, 2008).

Propriétés	Phase	MSE	RMSE	MAE	Coefficient de corrélation R
Ouvrabilité	Apprentissage	1.276	1.129	0.944	0.916
	Test	1.029	1.014	0.879	0.920
Temps V-entonnoir	Apprentissage	2.937	1.713	1.206	0.891
	Test	3.163	1.778	1.142	0.898
Résistance à la compression	Apprentissage	7.768	2.787	2.097	0.979
	Test	8.488	2.913	2.298	0.979
Rétivité électrique	Apprentissage	0.362	0.601	0.432	0.981
	Test	0.626	0.791	0.552	0.970
UPV	Apprentissage	1756.6	41.911	32.161	0.903
	Test	1732.1	41.618	27.989	0.934

Lim et al., (2004) ont utilisé les algorithmes génétiques pour développer une nouvelle méthode de formulation des bétons à hautes performances (BHP). La Figure 2.5 représente le processus de développement du modèle par ces auteurs.

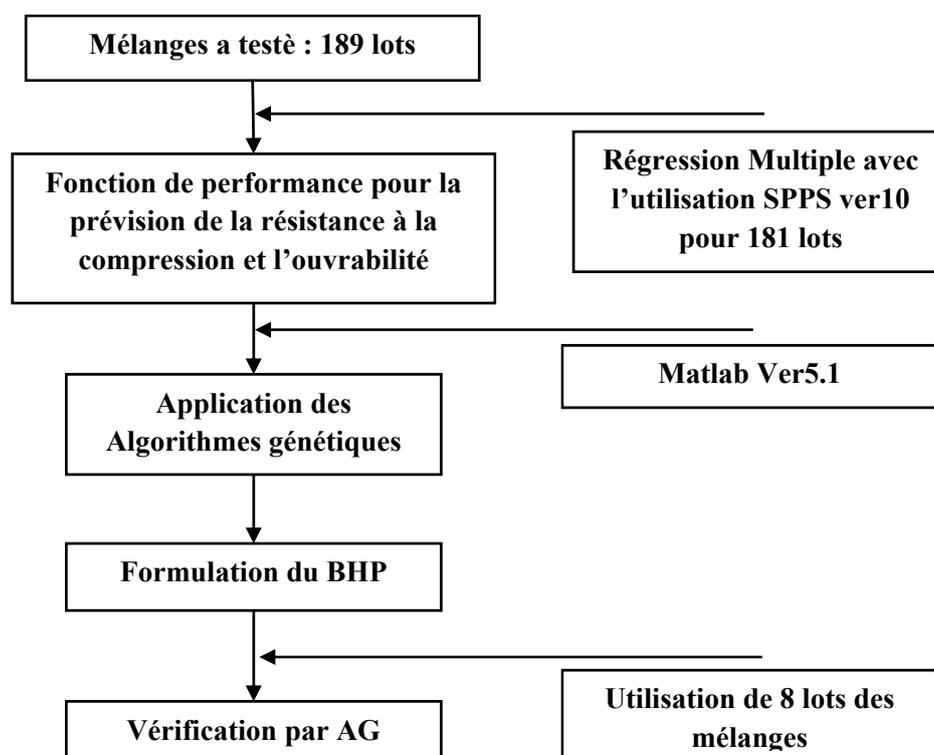


Figure 2.5 – Processus de développement du modèle (Lim et al., 2004).

La variation des erreurs en fonction nombre d'itération est montrée sur la Figure 2.6. On constate que l'erreur calculé avec les AGs et les valeurs expérimentales diminue avec l'augmentation de nombre d'itération.

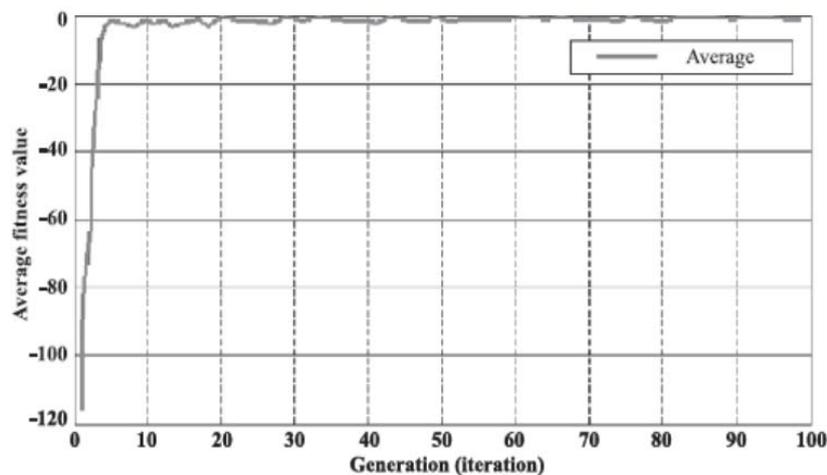


Figure 2.6 – Relation entre l'erreur et nombre d'itération (Lim et al., 2004)

L'étude réalisée par Lim et al., (2004) montre que la méthode de formulation des BHPs basée sur les algorithmes génétique est capable de prédire la composition du béton (Tableau 2.2), à partir de la résistance à la compression et de l'ouvrabilité, avec une grande précision.

Tableau 2.2– Résultats d'erreur obtenue par AG (Lim et al 2004)

Cas	E/L (%)	E (kg/m ³)	Sa/Gr (%)	FS (%)	SP (kg/m ³)	Erreur moyenne (%)
1 (erreur) (%)	0	0.63	5.13	0	3.62	1.88
2 (erreur) (%)	4	1.88	2.56	0	3.33	2.35
3 (erreur) (%)	4.35	3.23	0	0	5.544	2.62
4 (erreur) (%)	0	2.76	2.70	6.67	10.26	4.48

Récemment, Chopra et al., (2016) ont proposé des modèles basés sur les algorithmes génétiques de prévision de la résistance à la compression de béton avec et sans cendres volantes. Il est à noter que les données utilisées pour le développement de ces modèles sont des données d'un seul chercheur. Les critères d'évaluation des modèles choisis par les auteurs sont le coefficient de détermination R^2 et la racine carrée de l'erreur quadratique moyenne RMSE. Les équations de prédiction générées à l'aide des modèles proposées sont très fastidieuses comme est présenté dans la figure 2.7

$$\begin{aligned}
f_{28} &= \sqrt{CA} \left(\left(\left(\left(\left(\left(\left(\frac{(FA + FA)}{FA} \right) + \left(\sqrt{FA} + \left(FA + 0.640295148 \right) + \frac{\left(\left(\left(FA/0.661794484 \right) + \sqrt{CA} \right) \right) \right) \right) \right) \right) \right) + CA \right) + CA \right) + FA \right) \\
&\quad - \sqrt{\left(\sqrt{\left(\sqrt{\left((1 + FA) + FA \right) * W \right)} \right)} \right)^{-1}, \\
f_{56} &= \left(\left(\left(\frac{\left(W + \left(\sqrt{\left((W + W) \right) * W} \right) * f_{28} \right)}{\left(W * \left(f_{28} + \left(W + \left(\left(f_{28} + \sqrt{\left(f_{28} \right) + W \right) + f_{28} \right) \right) \right) \right) \right) + \left(W + 0.488720804 \right) * f_{28} \right), \\
f_{91} &= \left(\sqrt{\left(\left(\left(\left(f_{56} * \frac{\sqrt{\left(\left(\left(\left(f_{28}/W \right) / W \right) + \left(\left(\sqrt{\left(W * \left(CA - FA \right) + f_{28} \right) \right) + f_{28} \right) \right) \right) \right) \right) \right) \right) * \left(W + \left(\frac{f_{28}}{W} \right) * \left(W * W + \left(\frac{f_{28}}{W} \right) \right) \right) \right), \\
f'_{28} &= \left(\sqrt{CA} \left(W + \left(\left(\left(FA * \sqrt{\left(\left(\left(FA + CA \right) + FA \right) * FA \right) \right) + \left(FA + \left(\sqrt{CA} + \left(W + CA \right) + W \right) \right) + CA \right) + \left(\sqrt{FA} + FA \right) + \left(W + FA \right) \right) \right)^{-1}, \\
f'_{56} &= \left(\sqrt{\left(\frac{\left(\left(\left(-6.43e - 002 + f'_{28} \right) + \sqrt{\left(\left(\left(\sqrt{\left(\sqrt{CA} \right) * CA \right) \right) \right) \right) \right) \right)}{\sqrt{\left(\left(\left(\sqrt{CA} * \left(\left(\left(\left(W/f'_{28} \right) * \left(f'_{28} \pm 6.78e - 002 \right) \right) + \sqrt{FA} \right) \right) / \sqrt{\left(\sqrt{CA} \right) + f'_{28} \right) \right) \right) \right) \right) * f'_{28}}, \\
f'_{91} &= \left(\sqrt{\left(\left(\left(\left(W * 0.577551961 \right) * \sqrt{\left(\left(\left(\left(W * 0.572648823 \right) \right) \right) \right) \right) \right) \right) * \left(f'_{28} * 3.1462729 \right) \right),
\end{aligned}$$

Figure 2.7 – Modèles de prévision de la résistance à la compression proposée par Chopra et al., (2016)

Dont f_{28} , f_{56} et f_{91} sont les résistances à la compression du béton sans cendres volantes et f'_{28} , f'_{56} et f'_{91} sont les résistances à la compression du béton avec cendres volantes.

Les paramètres d'algorithmes génétiques adoptés par les chercheurs sont présentés dans le tableau 2.3

Tableau 2.3 – Paramètres choisis pour l'AG (Chopra et al., 2016).

Paramètres	Valeur	Description
Taux d'apprentissage	75%	—
Méthode de Sélection	Tournement	—
Remplacement tournement	3	—
Maximum generations	100000	nombre maximal d'itérations
Croissement	0.7	Probabilité de croisement
Mutation	$5.e - 002$	Probabilité de mutation
Mu	100	Taille de population
Lamda	150	Nombre d'enfant produits
Objectives	COD, RMSE	Coefficient de détermination et la racine des moyennes carrées

Les résultats du R^2 et RMSE sont présentés dans le tableau 2.4.

Tableau 2.4 – Résultats du Modèle AG de prévision (Chopra et al., 2016)

Type de béton	Age	R^2	RMSE
Béton sans ajouts*	28	0.77438	0.01067
	56	0.99999	0.00550
	91	0.99999	0.00644
Béton avec ajouts	28	0.93781	0.01415
	56	0.94483	0.00910
	91	0.96681	0.00689

* ajouts cimentaire : Cendres volantes

A partir de ces résultats (Tableau 2.4), les modèles AGs de prévision développés dans cette étude présentent une grande précision, les valeurs trouvées par les modèles sont très proches aux valeurs expérimentales où les valeurs du coefficient de corrélation R^2 sont tous supérieurs à 0.90 sauf pour la résistance à la compression à 28 jours, des bétons sans cendres volantes, on peut la considérer comme limite du modèle.

2.4.2 Application des réseaux de neurones

Oh et al., (1999) ont employé un réseau de neurones artificiels comme outil pour la conception des mélanges de béton. L'architecture du réseau de neurones la plus adaptée était à trois couches du type à Rétropropagation (Figure 2.8).

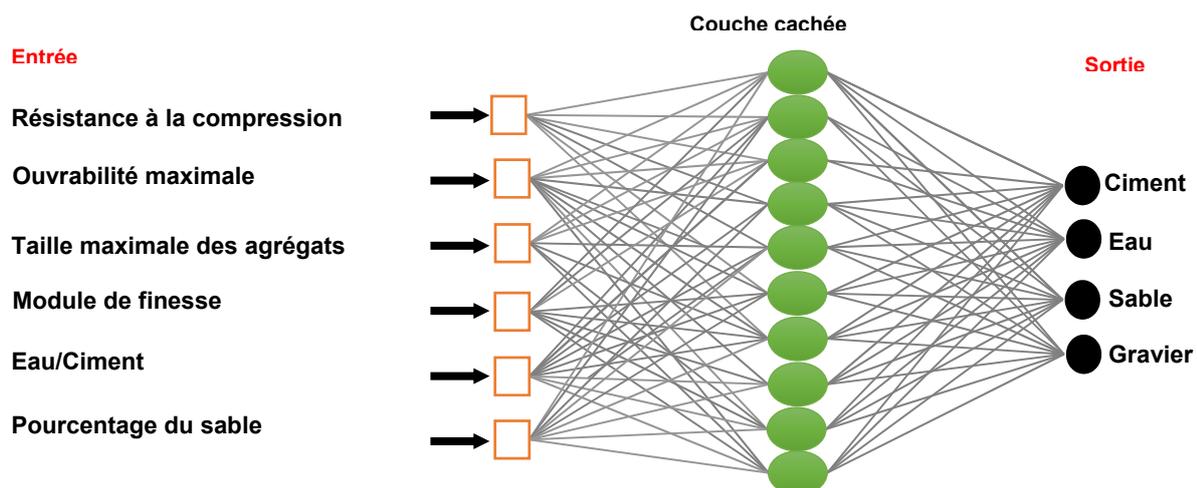


Figure 2.8 – Architecture du réseau développé par Oh et al., (1999)

L'objectif de leur application est de trouver les quantités de ciment, d'eau, de sable et de gravier. Ils ont utilisé comme paramètre d'entrée 6 propriétés qui sont: la résistance, l'ouvrabilité maximale, le rapport E/C, le module de finesse du sable et le pourcentage du sable.

L'application de ce réseau de neurones à la détermination des proportions du mélange de béton nécessite beaucoup de données. Les données analytiques sont employées au lieu des données expérimentales. Comme résultat de la combinaison des données montrées ci-dessus, il était possible d'obtenir 192 combinaisons de données.

Pour l'apprentissage du réseau neurones à rétropropagation, 180 combinaisons de données ont été employées et 12 combinaisons ont été utilisées pour la phase de test.

En outre, pour examiner la fiabilité du réseau, encore 16 combinaisons de données ont été obtenues. Ces données sont différentes des 12 données précédentes, choisies sur les valeurs suivantes :

- Résistance à la compression : (kg/cm^2) : 220 et 280.
- Taille maximale de l'agrégat (mm) : 15, 20, 25 et 40.
- Ouvrabilité (cm) : 8 et 12.
- module de finesse de sable : 2 et 8.

Le réseau a utilisé des données dans 4 ensembles, les résultats d'apprentissage et de test de ce réseau sont énumérés dans le tableau 2.5.

Tableau 2.5 – Résultats de l'apprentissage et de test (Oh et al., 1999)

Cas	Erreur d'apprentissage		Itération	Nombre de données d'apprentissage	Nombre de données de test	
	Désirée	Calculée				
1	0.010	0.0099	027.264	180	12	16
2	0.005	0.0049	157.808	180	12	16
3	0.010	0.0099	234.428	180	12	16
4	0.010	0.0099	340.375	372	12	16

D'après Oh et al., (1999), l'utilisation des réseaux de neurones pour la détermination des proportions de mélange du béton est très prometteuse. Les proportions du mélange prouvent que les teneurs en unité des composants du béton peuvent être obtenues avec une erreur de l'ordre de 5.9%. (Boukhatem, 2003).

Öztaş et al., (2006) ont utilisé les RNAs pour prédire la résistance et l'ouvrabilité d'un béton à hautes performances «BHP». Le modèle de réseaux de neurones développé comporte deux sorties : la résistance et l'ouvrabilité et 7 entrées : le rapport E/L, la quantité d'eau, le rapport sable/agrégats, la teneur en cendres volantes, le pourcentage d'entraîneur d'air, le

dosage du superplastifiant et la quantité de la fumée de silice sont indiqués dans le Tableau 2.6.

Tableau 2.6 – Paramètres d'entrée de la base de données (Öztaş et al., 2006)

Paramètre d'entrée	Minimum	Maximum
Eau/ Liant (%)	18	45
Eau (kg/m ³)	140	165
Sable/Granulats(%)	35	52
endre volante (%)	0	20
entraîneur d'air (kg/m ³)	0.036	0.078
fumé de silice(%)	5	25
superplastifiant (kg/m ³)	1.89	36.5

L'architecture de réseau de neurone développée pour ce modèle est un perceptron multicouche représenté dans la figure 2.9.

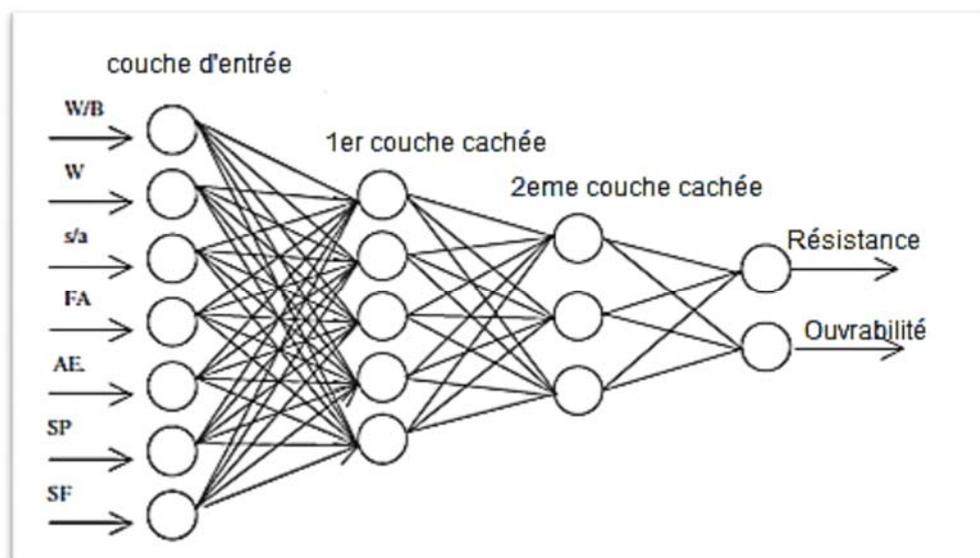


Figure 2.9 – Modèle de RNA proposé par Öztaş et al., (2006)

L'algorithme d'apprentissage utilisé dans l'étude est l'algorithme de gradient conjugué (SCGA), le processus d'apprentissage est effectué sous Matlab. La fonction d'activation est une fonction sigmoïde.

Ils ont employé des données de 187 différentes formulations des bétons BHP, 169 données utilisées pour l'apprentissage et 18 données pour le test (Tableau 2.7). Le choix des ensembles de données est aléatoire.

Tableau 2.7– Les paramètres utilisés dans le modèle de réseau de neurones (Öztaş et al., 2006).

Paramètres	RNA
Nombre de données	187
Nombre de données choisies pour l'apprentissage	169
Nombre de données choisies pour le test	18
Nombre d'entrées	07
Nombre de sorties	02
Nombre de couches cachées	02
Nombre de neurones de la 1ère couche	05
Nombre de neurones de la 2ème couche	03
L'algorithme d'apprentissage utilisé	Gradient conjugué
Type de la fonction d'activation	Sigmoïdal
Nombre de cycles d'apprentissage	10000

Une comparaison entre les valeurs expérimentales et les valeurs de RNAs est représenté graphiquement sur les Figures 2.10 et 2.11.

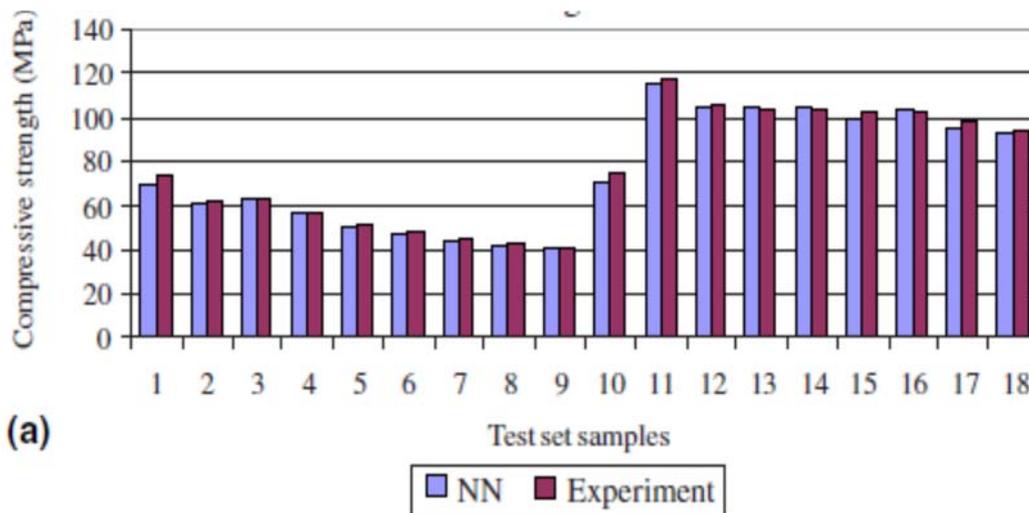


Figure 2.10 – Comparaison entre la résistance expérimentale et la résistance prédite par les RNAs (Öztaş et al., 2006).

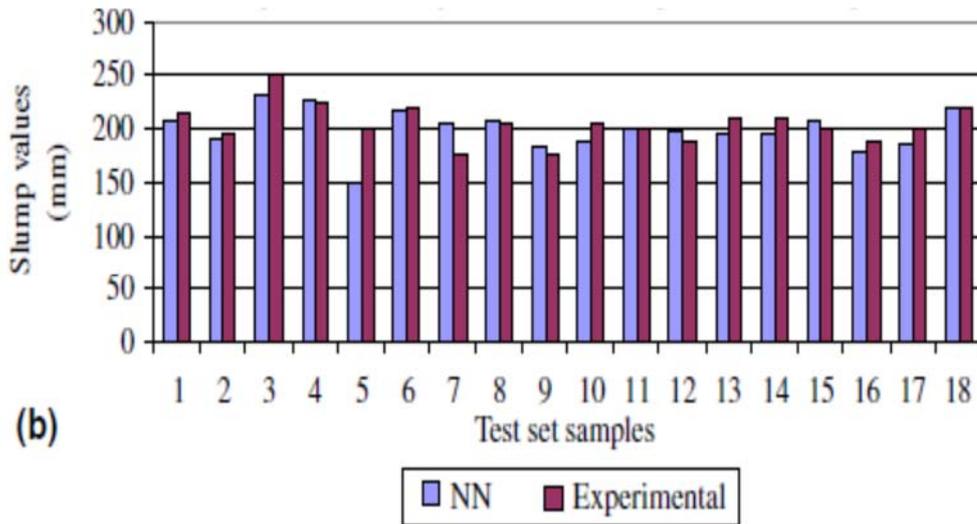


Figure 2.11 – Comparaison entre l'ouvrabilité expérimentale et l'ouvrabilité prédite par les RNAs (Öztaş et al., 2006).

Les résultats représentés dans les figures 2.10 et 2.11, montrent une convergence entre les valeurs expérimentales et les valeurs trouvées par le modèle développé. La distribution de l'erreur dans les différents échantillons est illustrée dans les figures 2.12 et 2.13.

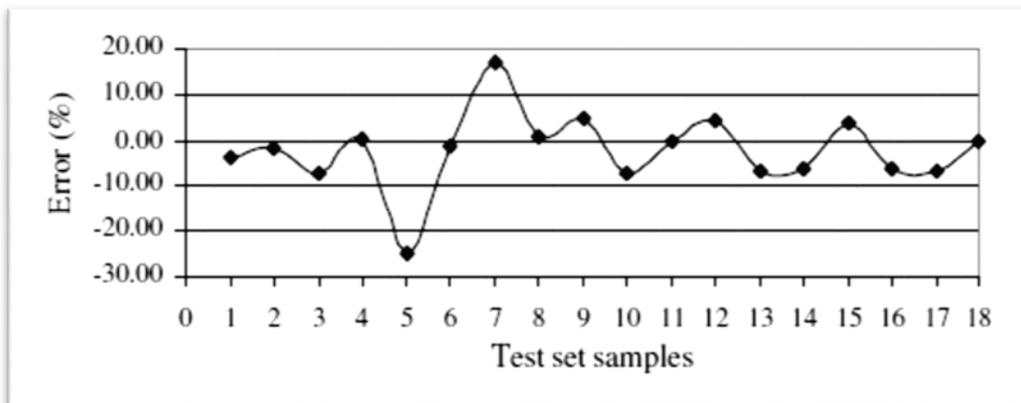


Figure 2.12 – Distribution d'erreur de la phase test pour l'ouvrabilité (Öztaş et al., 2006).

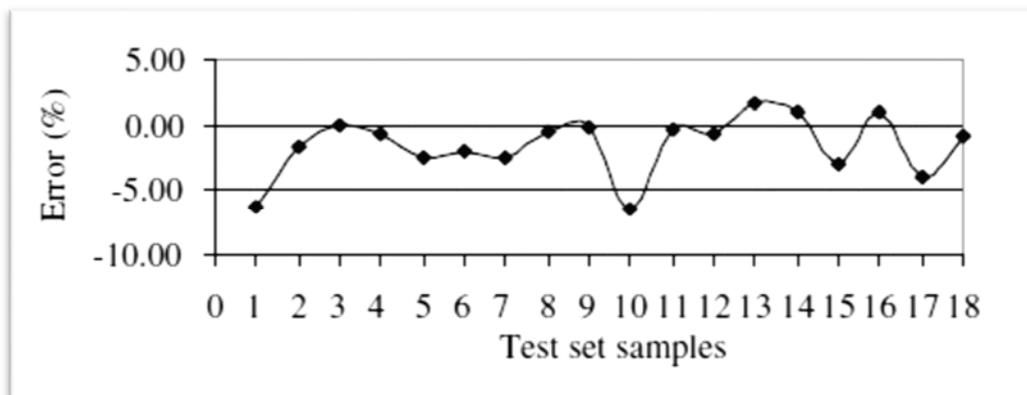


Figure 2.13 – Distribution d'erreur de la phase de test pour la résistance (Öztaş et al., 2006).

On peut constater que l'erreur dans la plupart des résultats de la prévision de la résistance est inférieure à 6%, avec des valeurs inférieures ou égales à 3% pour 77% des échantillons. Pour les résultats de l'ouvrabilité obtenue, 88% des résultats inférieurs à 9%, et des valeurs de 17%, 25% pour les échantillons 5 et 7.

Le coefficient de corrélation R pour l'apprentissage et le test a atteint une valeur de 99%, les valeurs de RNA sont très proches des valeurs expérimentales. Les résultats trouvés montrent que le modèle de réseau de neurone proposé est excellent pour la prévision de la résistance à la compression et de l'ouvrabilité.

Un modèle de prévision de la résistance à la compression a été élaboré par [Ni et Wang \(2000\)](#), l'architecture proposée est illustré dans la figure 2.14

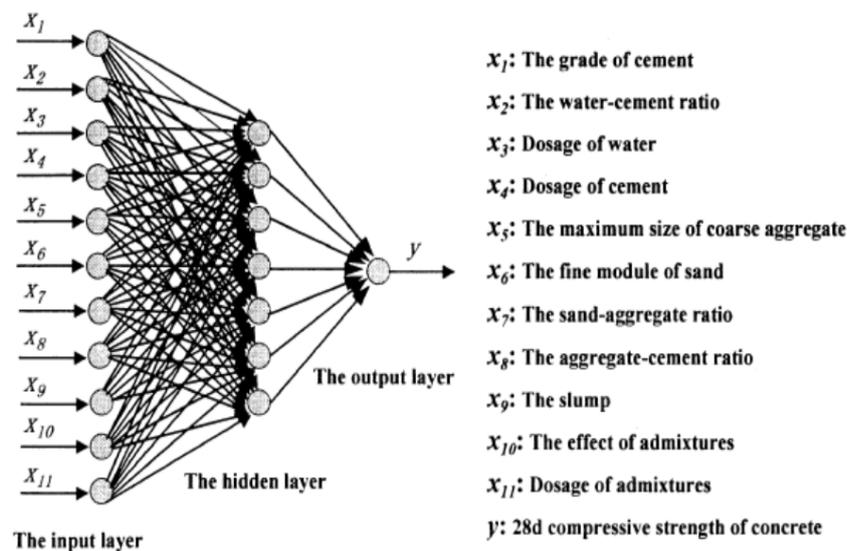


Figure 2.14 – Architecture du modèle de prévision ([Ni and Wang, 2000](#)).

Les auteurs ont conclu que :

- les modèles de prévision à l'aide de RNA fournissent une solution rapide pour prévoir une résistance à la compression de béton de 28 jours en fonction de certains de ses facteurs d'influence. Cette méthode intelligente de calcul sera utile pour les ingénieurs en génie civil et les concepteurs de béton.
- les modèles RNA atteignent une bonne précision de prédiction. Certains effets des compositions du béton sur la résistance sont conformes aux résultats trouvés dans la technologie de béton. Par conséquent, l'application des modèles RNAs à la prédiction de la résistance à la compression de béton est très pratique.

Une autre application des RNAs pour la prévision de la résistance à la compression à différents âges 1, 2, 7, 28, 56, 90 et 180 jours, d'un béton qui contient du Métakaolin et de

condres volantes, faite par Saridemir (2009). Cet auteur a proposé deux modèles d'architecture des réseaux de neurones (Figure 2.15). Les plages des données utilisées (Entrée–Sortie) dans la formulation de ces modèles « apprentissage et tests » sont présentés dans le tableau 2.8. Les paramètres de RNA-1 et RNA-2 sont présentés dans le tableau 2.9.

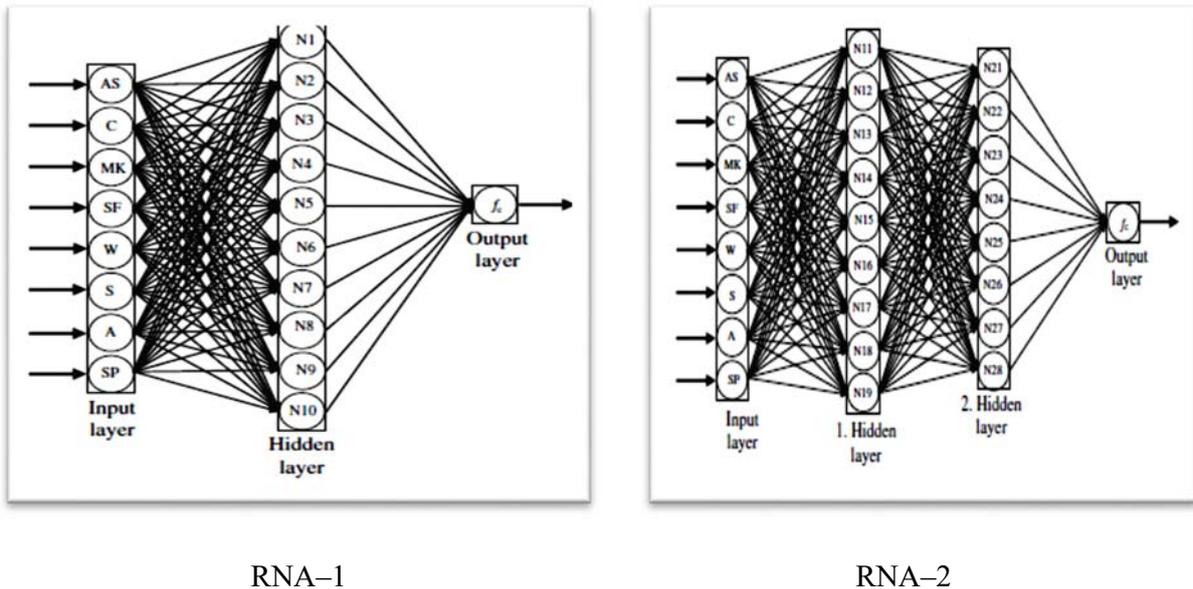


Figure 2.15 – Architectures proposées pour la prévision de la résistance (Saridemir, 2009).

Tableau 2.8 – Données utilisées pour l'apprentissage et tests (Saridemir, 2009).

		Données utilisé pour la phase d'apprentissage et test	
		Minimum	Maximum
Variables d'entrées	Age (jour)	1	180
	Ciment (Kg/m ³)	328	500
	Métakaolin Kg/m ³)	0	100
	fumée de silice (Kg/m ³)	0	75
	Eau	135	205
	Sable	648	725
	Granulats	1050	1087
	Superplastifiant (L/m ³)	0	43
Variables de sortie	Résistance à la compression (MPa)	24.50	120.30

Tableau 2.9 – Paramètres des deux modèles de réseau neurone (Saridemir, 2009).

Paramètres	RNA-1	RNA-2
Nombre de données	195	195
Nombre de données choisi pour l'apprentissage	130	130
Nombre de données choisi pour le test	65	65
Nombre d'entrées	08	08
Nombre de sorties	01	01
Nombre de couches cachés	01	02
Nombre de neurones de la 1ère couche	10	09
Nombre de neurones de la 2ème couche	–	08
L'algorithme d'apprentissage utilisé	Rétropropagation	Rétropropagation
Type la fonction d'activation	sigmoïdal	sigmoïdal
Nombre de cycles d'apprentissage	50.000	50.000

Après les phases de l'apprentissage et de tests, les deux modèles sont déterminés. Les résultats trouvés sont représentés dans la Figure 2.16.

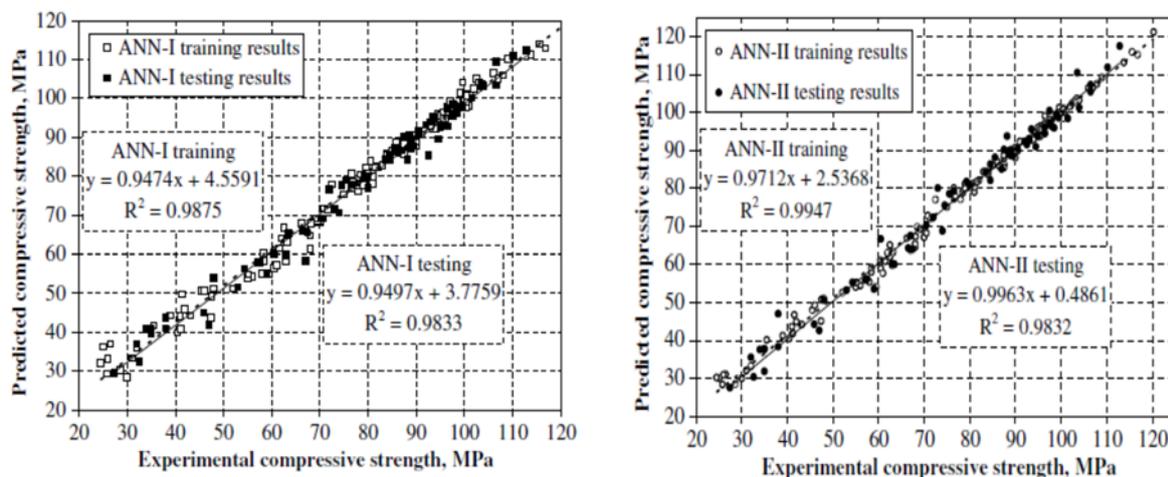


Figure 2.16 – Comparaison entre les valeurs la résistance expérimentales de RNA-1 et RNA-2 (Saridemir, 2009).

Il est clair d'après ces résultats (Figure 2.15) que les valeurs expérimentales sont presque identiques avec les valeurs prédites par les RNAs. Le coefficient de détermination R^2 est égal à 0.98 et 0.99 pour RNA-1 et RNA-2 respectivement. Ces valeurs sont très satisfaisantes pour dire que les modèles développés dans cette étude sont très puissants pour la prévision de la résistance à la compression d'un béton qui contient des cendres volantes et du Métakaolin.

Bellalia Douma et al., (2016) ont appliqué la technique de Réseaux de Neurones Artificiels (RNAs) pour prédire les différentes propriétés du béton auto-plaçant (BAP) contenant des cendres volantes. Un modèle a été développé afin de prédire les propriétés du BAP à l'état frais et à l'état durci.

L'objectif de ce modèle est de créer une application basée sur les RNAs pour prédire avec la même architecture les propriétés les plus importantes à l'état frais à savoir l'étalement, l'écoulement à l'entonnoir en V et L-BOX combinés avec la propriété mécanique la plus importante (la résistance à la compression à 28 jours) basé sur les différents mélanges du BAP contenant des cendres volantes (Figure 2.17). L'étalement, l'essai d'écoulement à l'entonnoir en V et l'essai de L-BOX ont été utilisés pour évaluer respectivement les propriétés rhéologiques : la fluidité, la viscosité, la capacité de remplissage et la capacité de passage.

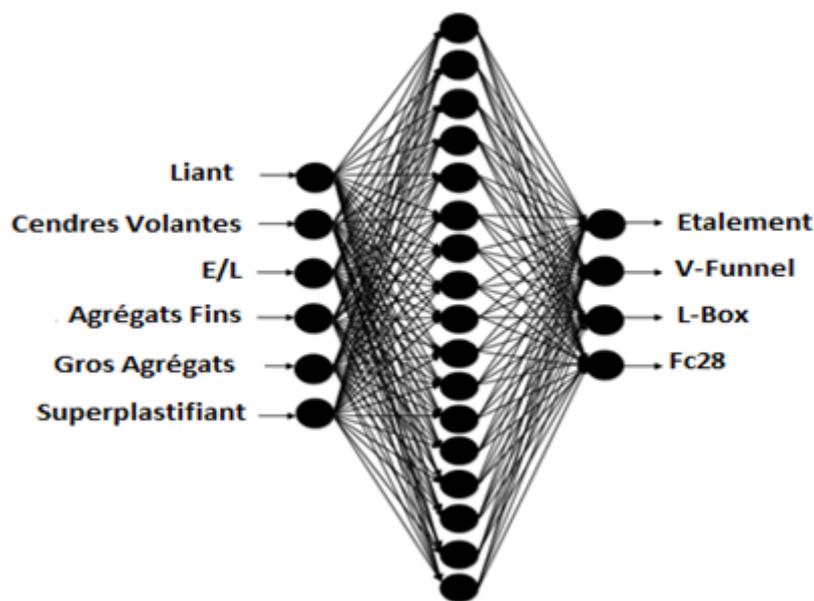


Figure 2.17 – Architecture du Modèle RN (Bellalia Douma et al., 2016).

Les résultats d'apprentissage et de test du modèle RN sont montrés respectivement sur la Figure 2.18 par comparaison des valeurs expérimentales et celles prédites par ce modèle. Cette figure montre significativement une forte corrélation prouvant la grande précision de ce modèle pour estimer ou prédire efficacement les propriétés désirés (Etalement (mm), Rapport L-Box, Temps de V- entonnoir (s) et Résistance à la compression à 28 jours (MPa)).

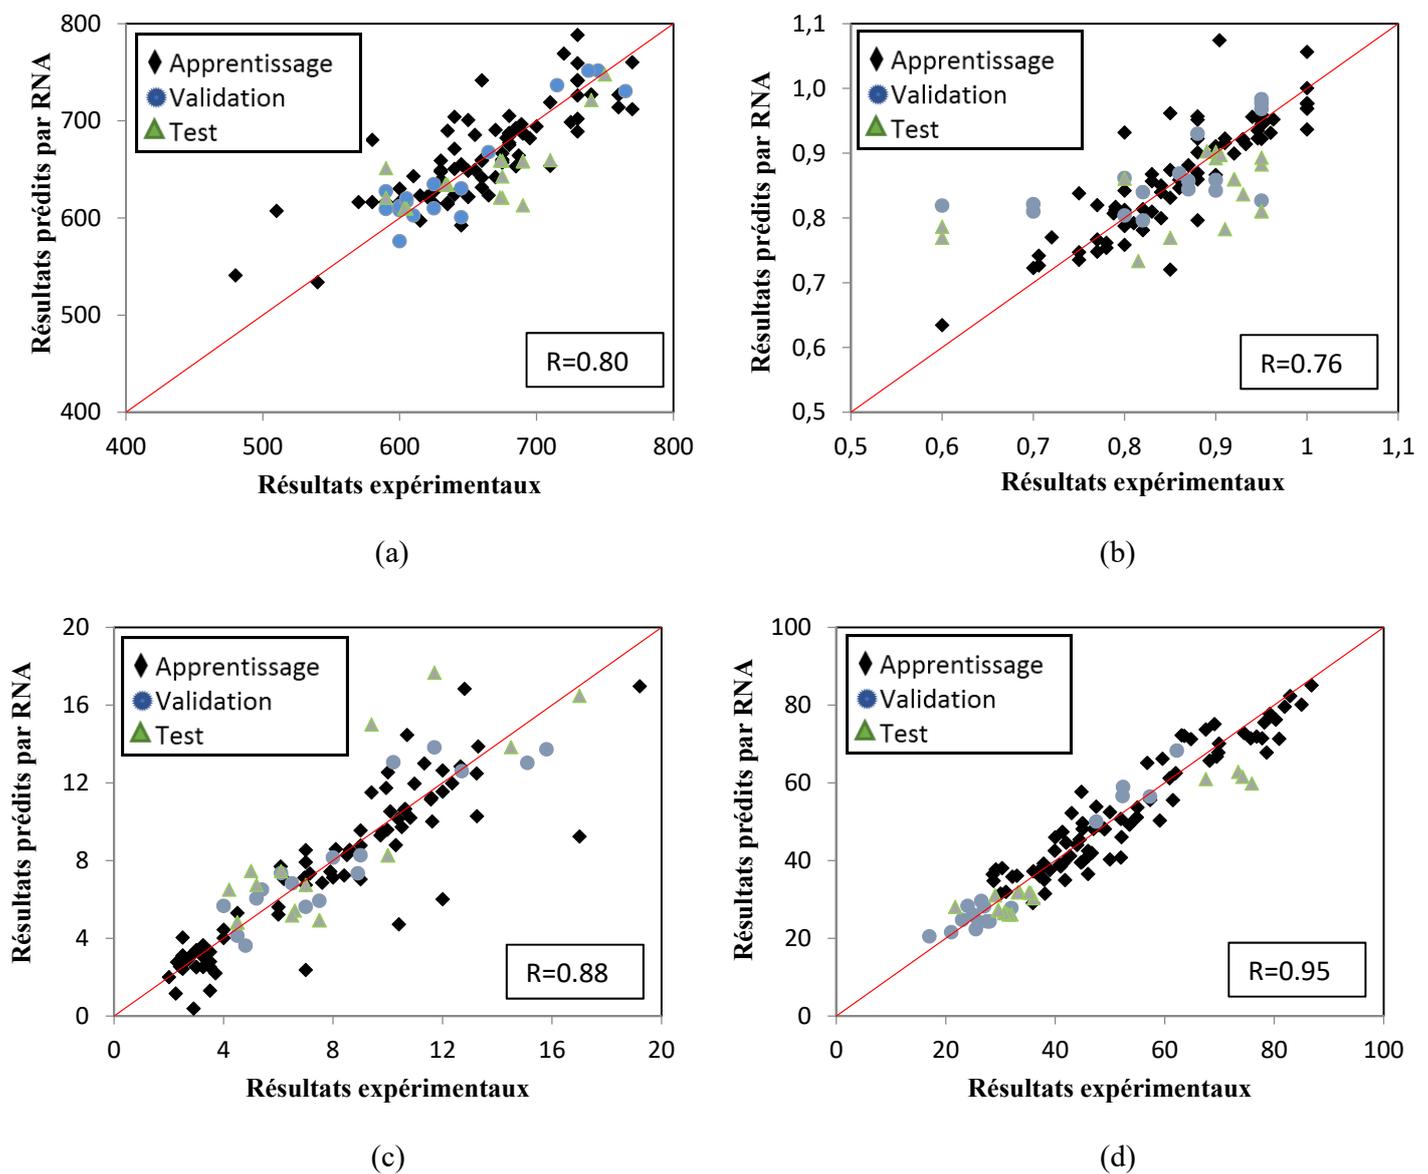


Figure 2.18 – Relation linéaire entre les propriétés expérimentales et prévues pour BAP
 (a) Etallement (mm), (b), Rapport L-Box (c) Temps de V-entonnor (s),
 (d) Résistance à la compression à 28 jours (MPa) (Bellalia Douma et al., 2016).

La capacité de prédiction du modèle RN proposé ainsi développé a été testée et validée par comparaison avec de nouvelles données obtenues par des résultats supplémentaires provenant d'autres chercheurs. La comparaison entre les valeurs prédites par le modèle développé et ceux obtenus expérimentalement par d'autres chercheurs est indiquée dans le tableau 2.10. La comparaison des résultats confirme la fiabilité du modèle développé.

Tableau 2.10 – Comparaison des résultats prédits par le Modèle RN1 et les résultats d'autres chercheurs (Bellalia Douma et al., 2016).

N	Auteur	Année	FA (%)	D (mm)			L-Box (H ₂ /H ₁)			V funnel(s)			Fc 28 (MPa)		
				Exp	RNA	E (%)	Exp	RNA	E (%)	Exp	RNA	E (%)	Exp	RNA	E (%)
1			0	600	594	1.0							66.8	61.78	7.5
2	Zhu	2003	20	600	610	1.7							71.3	66.36	6.9
3			30	630	612	2.8							49.9	53.4	7.0
4			0	679	734	8.0							60	75.82	26.4
5	Naik	2012	35	686	690	0.5							62	62.9	1.5
6			45	686	638	6.9							60	66.48	10.8
7			55	699	631	9.8							48	60.74	26.5
8			0	709	651	8.1	0.89	0.84	5.7				57.5	77.13	34.1
9			25	709	621	12.4	0.91	0.74	18.8				53.5	55.26	3.3
10	Turk	2013	30	702	640	8.8	0.94	0.77	17.9				55	56.72	3.1
11			35	705	657	6.7	0.95	0.8	15.6				58	57.19	1.4
12			40	701	676	3.5	0.96	0.84	12.7				59	57.81	2.0
13			0	720	652	9.4				8.1	5.7	29.4	73.3	63.06	14.0
14	Liu	2010	20	700	670	4.3				8.1	4.5	44.7	69.7	51.79	25.7
15			40	705	709	0.6				6.1	4.7	22.4	58.5	42.42	27.5
16			60	715	745	4.2				6.3	3.1	50.2	37.2	36.18	2.8

2.4.3 Application du système hybride RNAG

Une étude présentée par Akkurt et al., (2003) dont le but est d'utiliser le système RNAG pour la prévision de la résistance à la compression à 28 jours des mortiers.

Ils ont proposé un modèle RNAs avec une architecture composée d'une seule couche cachée de 20 neurones, et une seule sortie (f_{c28}). Les paramètres d'entrée, présentés dans le tableau 2.11, sont la composition chimique du ciment, la surface spécifique de Blaine, le taux de C₃S.

Les algorithmes génétiques ont été utilisés pour le traitement et pour séparer les données d'apprentissage et de test au début de la tâche de modélisation. Le taux d'apprentissage et le nombre de neurones de la couche cachée ont été ajustés pour élaborer un modèle avec une erreur minimale.

Tableau 2.11– Gammes de composants des ensembles de données (Akkurt et al., 2003).

Parameter input	Minimum	Maximum	Average
SiO₂ (%)	18.60	19.54	20.40
Al₂O₃ (%)	4.60	5.07	5.70
Fe₂O₃ (%)	3.50	3.64	4.00
CaO (%)	62.7	64.1	65.3
SO₃ (%)	2.2	2.7	3.1
Loss on ignition (%)	1.30	1.87	2.70
Free lime (%)	0.60	1.13	1.70
Aluminate modulus (Al₂O₃/Fe₂O₃)	1.30	1.39	1.60
Silicate modulus (SiO₂/(Al₂O₃+Fe₂O₃))	2.00	2.24	2.50
Na₂O (%)	0.10	0.21	0.30
K₂O (%)	0.70	0.78	0.80
Initial setting time (min)	95.00	156.77	225.00
Final setting time (min)	150.0	248.0	365.0
Compressive strength (MPa (or N/mm²))	47.60	53.14	58.40

Les auteurs ont trouvé que le système est capable de prédire la résistance à la compression à 28 jours avec une précision très satisfaisante. Le modèle développé pourrait être utilisé par les opérateurs de l'usine de fabrication de ciment pour choisir de manière optimale la résistance en fonction des propriétés de ciment mesurées.

Une étude récente effectuée par [Vinay Chandwani et al., \(2015\)](#) sur l'utilisation de modèle hybride réseau de neurone et algorithme génétique (RNAG) pour la prévision de l'ouvrabilité de béton. Les AGs ont été utilisés pour évoluer les poids de connexion et les bais initiaux afin de résoudre les problèmes majeurs des RNAs, l'arrêt rapide du système, à cause de la convergence vers les minimas locaux et la convergence lente vers l'optimum global. Les inputs et l'architecture RNA proposés dans cette étude sont illustrés dans la figure 2.19.

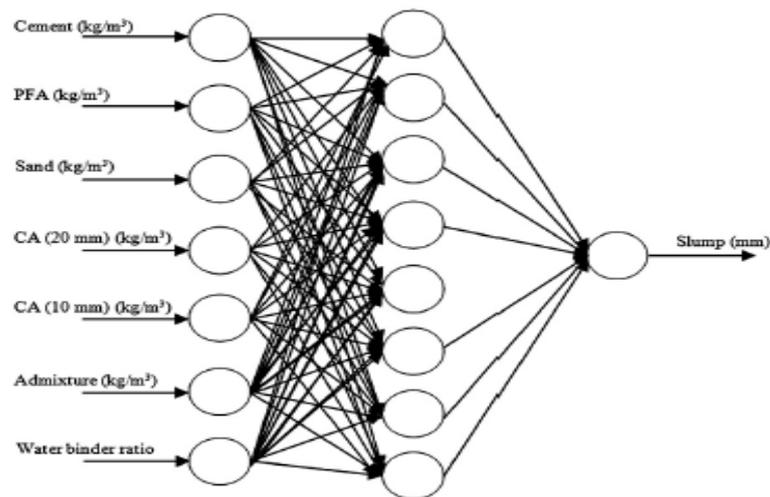


Figure 2.19 – Architecture du modèle proposé par Chandwani et al., (2015).

Une comparaison a été faite dans cette étude entre un modèle de prévision de l'ouvrabilité du béton développé par un RNA seul est par le système hybride RNAG. Les résultats trouvés sont montrés dans la Figure 2.20.

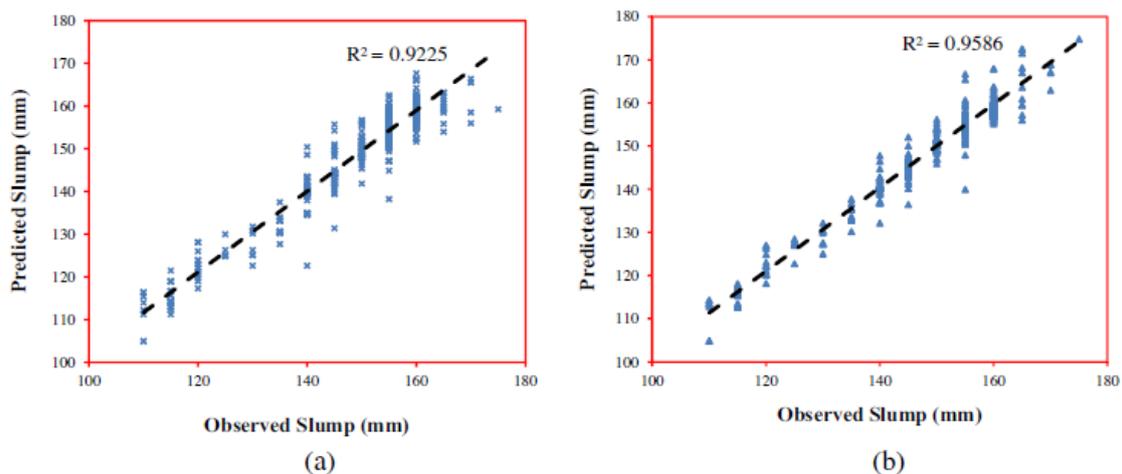


Figure 2.20 – Régression entre les valeurs d'ouvrabilités prédit par RNA (a) et RNAG (b) et les valeurs observées (Chandwani et al., 2015).

Il est clair que le système RNA seul ou le système hybride RNAG sont capables de prédire l'ouvrabilité de béton avec une grande précision. Par contre, en comparant le RNA seul et le RNAG, on remarque que le système hybride est plus performant et plus précis que le RNA seul avec R^2 égal à 0.95 et 0.92 respectivement. Le processus d'hybridation RNAG est illustré dans la figure 2.21

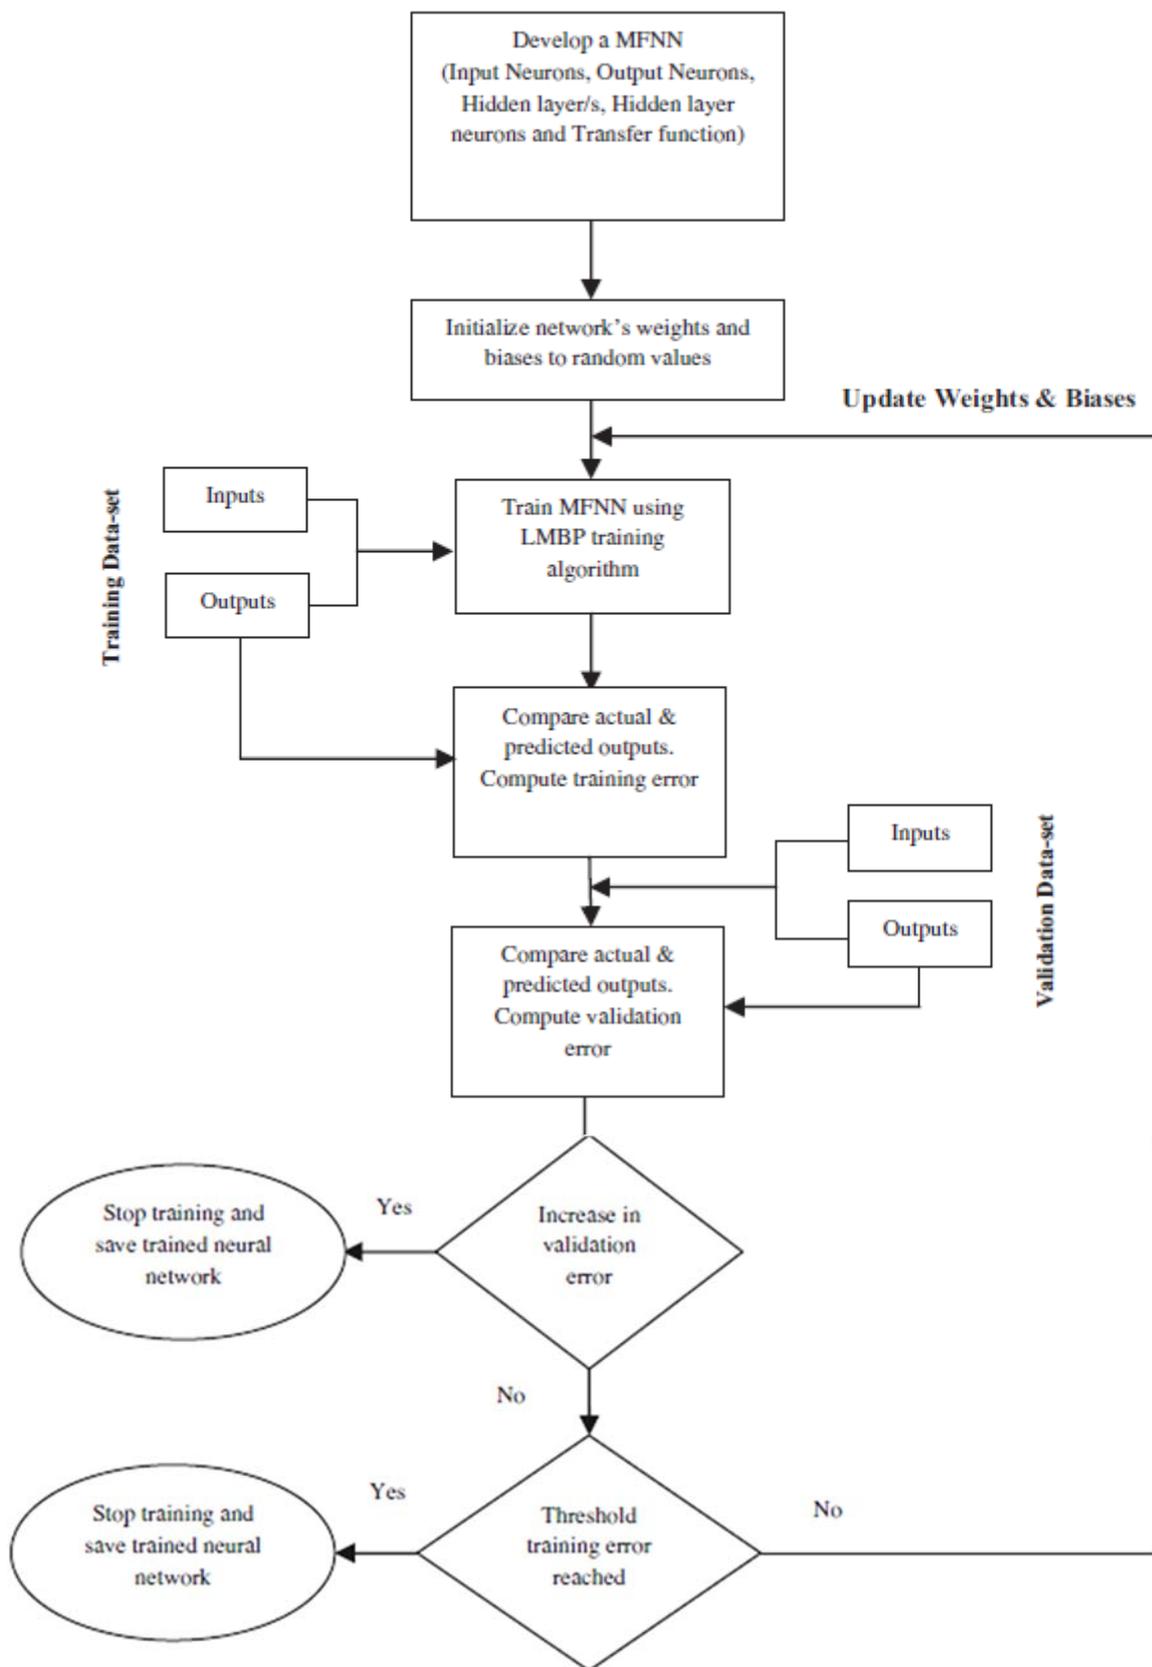


Figure 2.21 – Organigramme de système RNA assisté par AG (Chandwani et al., 2015).

2.5 Conclusion

Un nombre significatif de systèmes des réseaux de neurones et des algorithmes génétiques 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 RNAs 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 contenant des ajouts (laitier, pouzzolane naturelle, fumée de silice, cendres volantes, etc...) 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 bétons aux ajouts (PN et CV) en utilisant la structure hybride RNAG, elle est plus performante que les RNAs. La base de données, la méthodologie, le développement et l'implémentation de ces modèles seront discutés dans les chapitres suivants.

#

CHAPITRE 03

Conception de la Base de Données.

#

#

3.1 Introduction

La préparation de la base de données est une étape très importante pour la conception des modèles des réseaux de neurones-algorithmes génétique (RNAG), la performance du modèle est liée directement au nombre et à la fiabilité des données utilisées, deux ajouts minéraux, la pouzzolane naturelle et les cendre volantes ont été pris en considération dans le processus de développement des modèles de prévision de la résistance à la compression et de la formulation du béton.

La base de données a été construite à partir des résultats expérimentaux réalisés sur des bétons aux pouzzolanes naturelles et obtenus de diverses sources disponibles dans la littérature.

Pour les cendres volantes on a utilisé la base de données disponible dans le logiciel **SAICBA** (Système Automatisé Intégré basé sur la Connaissance pour les Bétons avec Ajouts) développé par [Boukhatem \(2011\)](#), une révision et une mise à jour a été faite en ajoutant d'autres données plus récentes.

Dans ce chapitre les aspects détaillés de la collecte et du filtrage de données concernant les bétons à la pouzzolane naturelle (PN) et aux cendres volantes (CV) vont être expliqués. Le processus de la collecte de données a été effectué dans deux phases. L'objectif de la première phase était de rassembler des données disponibles dans la littérature. La deuxième phase a impliqué la normalisation des données sélectionnées pour répondre aux exigences d'entrée du modèle de réseaux de neurones artificiels proposé.

3.2 Méthodologie de collection et d'organisation des données expérimentales

Les données concernant les bétons aux ajouts minéraux par substitution partielle du Ciment (C), par les Cendres Volantes (CV) ou par la Pouzzolane Naturelle (PN) ont été extraites et rassemblées des projets de recherche précédents de sources différentes dans la littérature pour construire la base de données.

Chaque ensemble se compose des vecteurs de facteurs influençant (constituants du béton), de la résistance à la compression et de l'ouvrabilité correspondante du béton (tableau 3.1).

Toutes les résistances testées sur les différents types d'éprouvettes ont été généralisées sur des cylindres de 100x200 cm sous des conditions de cures normales dans l'eau.

Tableau 3.1- Exemple d'un vecteur de facteurs influençant sur la formulation

Composants	Propriétés	
	Etat frais	Etat durci
Ciment.	Ouvrabilité,	Résistance à la compression
Ajouts minéraux	Pourcentage d'air,	Durabilité
Adjuvants chimiques	Masse volumique	
Agrégats	Température	
Eau.		

Les valeurs de la résistance à la compression collectées ont été mesurées sur différents types d'éprouvettes, des cubes 10x10x10cm, des cubes 15x15x15cm, des cylindres 10x20 cm et des cylindres 15x30cm. Pour cela, toutes les valeurs sont converties à l'aide de formules empiriques (Mirza, 2002) exprimées par les équations 3.1 et 3.2.

$$f_a = f_0 \left[0.58 + 0.42 \left(\frac{10}{a} \right)^{1/3} \right] \quad (3.1).$$

$$f'_{cylindre} = f_a \left[0.76 + 0.2 \log_{10} \left(\frac{0.95 f_a}{19.6} \right)^{1/3} \right] \quad (3.2).$$

Où : f_0 représente la résistance à la compression d'une éprouvette cubique de 10 cm, f et a représentent la résistance à la compression d'une éprouvette cubique de côté égale à « a » et $f'_{cylindre}$ représente la résistance à la compression d'un cylindre de 15x30 cm.

L'ouvrabilité a été mesurée par l'essai standard d'affaissement au cône d'Abrams. La gamme des constituants dans les bétons aux ajouts est indiquée dans le tableau 3.1.

La gamme des constituants et propriétés des bétons aux ajouts, la pouzzolane naturelle et les cendres volantes sont indiquées dans les tableaux 3.2 et 3.3 respectivement. Les compositions chimiques des ciments et de la pouzzolane naturelle sont indiquées dans les tableaux 3.4 et 3.5 respectivement.

Tableau 3.2 - Gammes des constituants et propriétés des bétons aux PN

Composants et propriétés	Données	
	Min	Max
Ciment (C) (kg/m ³)	176	480
Pouzzolane Naturelle (PN)	0	235
Agrégats Fins (AF) (kg/m ³)	408	892
Gros Agrégats (GA) (kg/m ³)	789	1200
Eau (E) (kg/m ³)	114	235
Superplastifiant (SP) (l/m ³)	0	2.25
Eau/Ciment (E/C)	0.31	0.81
Age (J) (Jours)	1	270
Résistance à la Compression (Rc) (MPa)	3	64.08

Tableau 3.3 - Gammes des constituants et propriétés des bétons aux CV

Composants et propriétés	Données	
	Min	Max
Ciment (C) (kg/m ³)	105	510
Cendres volantes (CV)	0	285
Agrégats Fins (AF) (kg/m ³)	600	960
Gros Agrégats (GA) (kg/m ³)	927	1338
Eau (E) (kg/m ³)	120	240
Superplastifiant (SP) (l/m ³)	0	1.97
Eau/Ciment (E/C)	0.26	0.75
Age (J) (Jours)	1	365
Résistance à la Compression (Rc) (MPa)	3.4	71.8
Ouvrabilité (Ouv.) (mm)	8	215

Tableau 3.4 - Composition chimique des ciments avec la pouzzolane naturelle.

Auteur	SiO ₂	Al ₂ O ₃	Fe ₂ O ₃	CaO	MgO	K ₂ O	Na ₂ O	SO ₃	SSB (m ² /kg)
Ramezaniipoor (1987)	-	-	-	-	-	-	-	-	-
Shannagt & Yeginobali (1995)	23.1	6.5	4.1	53.0	5.0	0.8	-	2.9	410
Vidéla et al (1996)	-	-	-	-	-	-	-	-	-
Turanli & Erdogan (1999)	19.1	7.0	3.0	58.2	1.1	-	-	3.5	308
Pekmezci & Akyuz (2003)	20.45	5.30	2.65	63.36	2.66	0.64	-	3.29	342
Tagnit-Hamou et al. (2004)	-	-	-	-	-	-	-	-	400
Hossain et al. (2006)	21.40	5.70	3.50	64.10	2.10	0.60	0.50	2.10	320
Uzal et al. (2007)	19.94	5.34	3.72	63.20	2.44	0.81	0.52	2.95	313
Naseer et al. (2008)	20.10	6.12	3.20	63.34	2.34	-	-	3.43	-
Kaid et al. (2009)	23.3	5.10	3.70	63.30	0.20	-	-	1.50	320
Olawuyi & Olusola (2010)	-	-	-	-	-	-	-	-	-

Tableau 3.5 - Compositions chimiques et surfaces massiques des pouzzolanes naturelles.

Auteur	SiO ₂	Al ₂ O ₃	Fe ₂ O ₃	CaO	MgO	K ₂ O	Na ₂ O	SO ₃	SSB (m ² /kg)
Ramezaniapoor (1987)	-	-	-	-	-	-	-	-	-
Shannagt & Yeginobali (1995)	40.1	13.4	12.1	9.7	10	1.5	1.4	-	420
	38.5	12.8	11.9	9.6	9.7	1.5	1.3	0.01	700
Vidéla et al (1996)	-	-	-	-	-	-	-	-	-
Turanli & Erdogan (1999)	56.0	12.6	3.7	13.4	1.1	-	-	1.8	-
Pekmezci & Akyuz (2003)	63.96	12.50	4.0	3.4	2.45	-	-	0.20	435
Tagnit-Hamou et al. (2004)	55.42	15.04	9.13	9.05	0.82	1.18	1.71	0.18	224
Hossain et al. (2006)	59.32	17.54	7.06	6.10	2.55	2.03	3.80	0.71	285
Uzal et al. (2007)	68.72	12.82	1.4	2.1	0.73	4.7	0.4	0.06	995
	70.96	13.4	1.16	1.72	0.28	4.65	3.2	-	413
	54.21	14.81	5.63	7.29	2.68	1.19	0.99	0.10	670
Naseer et al. (2008)	61.02	22.24	3.05	1.54	1.05	2.83	1.68	-	-
	57.7	20.53	4.62	4.82	1.30	3.40	3.06	-	-
Kaid et al. (2009)	56.30	17.0	8.60	9.80	1.80	-	-	-	450
Olawuyi & Olusola (2010)	48.75	16.26	2.13	11.67	4.24	5.71	3.83	-	-

Les compositions chimiques des ciments utilisées dans les bétons et les cendres volantes sont indiquées dans les tableaux 3.6 et 3.7 respectivement.

Tableau 3.6- Composition chimique des ciments utilisés pour les bétons aux cendres volantes

Auteur	SiO₂	Al₂O₃	Fe₂O₃	CaO
McCarthy and Dhir, (2005)	21.2	4.2	2.7	64.4
Bilodeau et al., (1994)	21,16	4,75	3,65	64,99
Ramezani pour and Malhotra, (1995)	20,32	4,94	2,55	62,58
Gopalan, (1995)	19,6	4,6	5	63,7
Simčič et al. (2015)	19,33	5,52	2,7	62,5
Shafiq et al. (2007)	--	--	--	--
Gardner (1990)	22,7	7,44	2,22	61,2
Ahmad et al. (2012)	--	--	--	--
Woo et al. (2011)	21.1	6.5	2.9	62.5
Chindaprasirt et al. (2007)	20,8	5,2	3,8	64,3
Bouzoubaâ and Fournier. (2003)	20,3	4,2	3	62.0
Ravindrarajah and Tam. (1989)	21,5	3,9	2,4	60,4
Jiang and Malhotra. (2000)	20,9	4,58	3,28	64,14
Felekoglu. (2006)	20,05	5,92	2,54	63,91
Al-Amoudi et al. (1996)	20,5	4,5	2,7	64,08
Gopalan and Haque. (1987)	--	--	--	--

Tableau 3.7- Compositions chimiques et surfaces massiques des cendres volantes

Auteur	SiO₂	Al₂O₃	Fe₂O₃	CaO
McCarthy and Dhir. (2005)	47.8	30.7	3.8	7.1
	47,33	25,44	13,82	1,81
Bilodeau et al. (1994)	49,02	26,69	12,31	2,37
	46,2	15,6	7,7	14,93
	46,38	15,32	7,38	19,34
Ramezani pour and Malhotra. (1995)	40,9	18,6	28,9	1,87
Gopalan. (1995)	52,7	26,5	4,26	7,44
	47,79	27,11	9,94	5,4
Simčič et al. (2015)	41,98	18,51	9,67	15,2
Shafiq et al. (2007)	50,2	28,59	13,17	2,55
Gardner. (1990)	50,4	26,6	11,2	2,04
Ahmad et al. (2012)	--	--	--	--
Woo et al. (2011)	49,9	19,2	10,1	8,21
Chindaprasirt et al. (2007)	44,4	23,4	10,4	13,1
	42,7	20,3	23,7	4,2
Bouzoubaâ and Fournier (2003)	52,4	23,4	4,7	13,4
Ravindrarajah and Tam. (1989)	51,7	22,5	12,1	4,2
	36,85	18,35	35,05	3,68
	52,35	23,35	4,65	13,38
	56,75	21,51	4,89	8,83
Jiang and Malhotra. (2000)	41,99	21,44	4,55	15,81
	56,2	30,05	5,06	1,06
	50,5	15,36	8,76	15,6
Felekoglu. (2006)	52	23,69	5,94	10,6
Al-Amoudi et al. (1996)	60,5	23	7,5	2,1
Gopalan and Haque. (1987)	61,4	25,5	1,44	4,2

3.3 Organisation de la base de données

Pour chaque modèle, les données sont divisées en trois parties, un ensemble pour la phase d'apprentissage, un ensemble pour la phase de test et un ensemble pour la phase de validation. D'une façon générale, la division sous le langage Matlab se fait automatiquement et d'une façon aléatoire : 70% pour la phase d'apprentissage, 15% pour la phase de test et 15 % pour la phase de validation. Mais après plusieurs essais pour une même architecture de réseau dans le système hybride RNAG, on a constaté qu'un bon choix du taux de division des trois phases peut donner de bons résultats.

Cependant, le taux de chaque phase ; l'apprentissage, le test et la validation, a été varié dans le processus du choix de l'architecture du réseau optimale qui sera détaillé dans le chapitre 4. Les résultats de division des trois phases sont mentionnés dans les tableaux 3.8 et 3.9 des deux types d'ajout.

L'ensemble des données représente un total de 412 compositions pour le modèle (M1) de prévision de la résistance des bétons à base de pouzzolane naturelle et 377 pour les modèle M2 et M3 de prévision et de formulation des bétons aux cendres volantes, constituant la base de données. Les tableaux 3.8 et 3.9 récapitulent l'organisation des données selon chaque ajout.

Selon les deux tableaux 3.8 et 3.9, on dispose au total de 789 valeurs. Ces résultats seront employés pour la conception et le test de la fiabilité des modèles de RNAG à développer. Pendant l'évaluation des données, certaines de ces formules de bétons ont été supprimées à cause de l'insuffisance d'information concernant les compositions utilisées.

Les données sont organisées et traitées avec le logiciel Excel, Ensuite, elles sont transférées dans des fichiers sous un format spécifique et sont ensuite utilisées pour entraîner la structure hybride RNAG.

Tableau 3.8 - Organisation de la base des données des modèles de prévision de la résistance pour les bétons a la PN

Source de Données	Modèle de prévision de la résistance M1
Ramezaniapoor (1987)	40
Shannagt & Yeginobali (1995)	36
Vidéla et al (1996)	60
Turanli & Erdogan (1999)	16
Pekmezci & Akyuz (2003)	15
Tagnit-Hamou et al. (2004)	15
Hossain et al. (2006)	126
Uzal et al. (2007)	20
Naseer et al. (2008)	18
Kaid et al. (2009)	48
Olawuyi & Olusola (2010)	16
Total	412
Nombre des données utilisées pour l'apprentissage	288(70%)
Nombre des données utilisées pour le teste	82 (20%)
Nombre des données utilisées pour la validation	42 (10%)

Tableau 3.9 - Organisation de la base des données des modèles de prévision de la résistance et de formulation pour les bétons aux CVs

Source de Données	Modèle de prévision M2	Modèle de formulation M3
McCarthy and Dhir (2005)	24	24
Bilodeau et al. (1994)	20	20
Ramezaniapour and Malhotra. (1995)	16	16
Gopalan. (1995)	24	24
Simčič et al. (2015)	20	20
Shafiq et al. (2007)	36	36
Gardner, (1990)	16	16
Ahmad et al. (2012)	18	18
Woo et al. (2011)	12	12
Chindaprasirt et al. (2007)	11	11
Bouzoubaâ and Fournier, (2003)	44	44
Ravindrarahaj and Tam, (1989)	24	24
Jiang and Malhotra, (2000)	35	35
Felekoglu, (2006)	20	20
Al-Amoudi et al. (1996)	21	21
Gopalan and Haque. (1987)	36	36
Total	377	377
Nombre des données utilisées pour l'apprentissage	302 (80%)	339 (90%)
Nombre des données utilisées pour la validation	57 (15%)	19 (5%)
Nombre des données utilisées pour le teste	18 (5%)	19 (5%)

3.4 Normalisation des Données

Les composants qui forment le vecteur d'entrée du réseau de neurones ont différentes limites quantitatives, ainsi une normalisation des données est nécessaire. Il existe plusieurs translations linéaires qui peuvent être employées pour normaliser les composants du vecteur d'entrée afin qu'ils prennent des valeurs entre -1 et 1. Celle parmi les plus utilisées et que nous avons employés dans ce travail apparaît dans l'équation 3.3 suivante :

$$X_n = \frac{(y_{max} - y_{min}) * (X - X_{min})}{(X_{max} - X_{min})} + y_{min} \quad (3.3)$$

Où :

X_n est le vecteur de données normalisées, X est le vecteur d'entrée des données réelles, X_{min} et X_{max} sont le minimum et le maximum des éléments du vecteur d'entrée X respectivement.

y_{max} et y_{min} sont les valeurs de normalisations égales à 1 et -1 respectivement

Après l'apprentissage du réseau les composants du vecteur de sortie Y doivent être transférés de valeurs comprises entre -1 et 1 en valeurs réelles (dé-normalisation) par l'équation 3.4 suivante :

$$y = \frac{(Y_n - y_{min}) * (X_{tmax} - X_{tmin})}{(y_{tmax} - y_{tmin})} + X_{tmin} \quad (3.4)$$

Où le Y_n est le vecteur de sortie de données normalisés et Y le vecteur de sortie des données réelles. X_{tmin} et X_{tmax} sont le minimum et le maximum des éléments du vecteur de sortie Y respectivement.

3.5 Conclusion

Ce chapitre a fourni une description détaillée de la méthodologie employée pour rassembler et normaliser les données expérimentales. Les données ont été collectées à partir de différents travaux de recherche réalisée par différents chercheurs qui ont utilisées une variété de matériaux, plusieurs types de pouzzolane naturelle et différents types de granulats.

La base de données utilisées pour la construction des modèles de prévision de la résistance à la compression et de formulations de béton contenant des cendres volantes développés est collectée à partir de différentes sources, plusieurs paramètres ont été ignorés, tels que la température, l'indice d'activité de chaque type de pouzzolane, le type des granulats utilisés, le type de ciment, le type de superplastifiant, la qualité d'équipement...etc.

En raison de non normalisation des données, elles ont dû être examinées et filtrées par la technique de normalisation de Min-Max car ce dernier est en accord avec les bornes de la fonction de transfert tangente hyperbolique utilisée. En outre, la base de données a été fractionnée en trois sous-ensembles : un pour la formation (apprentissage) et deux autres pour le test et la validation respectivement pour chaque modèle.

Les trois sous-ensembles sont employés à apprendre et valider l'exécution des trois modèles RNAG (M1, M2 et M3) proposés. Le processus de développement de ces derniers ; la structure hybride RNAG, l'architecture, les paramètres d'apprentissages et les paramètres des algorithmes génétiques font l'objet du chapitre 4 suivant.

#

CHAPITRE 04

*Développement des modèles et
conception du logiciel de formulation.*

#

#

4.1 Introduction

L'approche de l'intelligence artificielle a été utilisée pour l'élaboration du logiciel de formulation des bétons aux ajouts cimentaires comme il a été mentionné dans les chapitres précédents, en développant un nouveau système combiné entre la technique des réseaux de neurones artificiels et les algorithmes génétiques.

Le logiciel : **CMS v.01 « Concrete Mix Software version 01 »** est destiné à la formulation, par la prédiction des propriétés ou l'optimisation de la composition des bétons, contenant de la pouzzolane naturelle ou des cendres volantes. Deux propriétés essentielles du béton « l'ouvrabilité et la résistance à la compression à un âge donné », sont prises en considération pour la conception des modèles.

Dans ce chapitre on va décrire la méthodologie, la description de développement du modèle hybride RNAG utilisé pour la conception des modèles de prévision de la résistance à la compression ainsi que la formulation des bétons. Le développement du système hybride RNAG a été accompli à l'aide d'un "Toolbox Neural Network and Genetic Algorithm" du logiciel MATLAB version 2014a, qui fonctionne sur la plate-forme Windows.

4.2 Méthodologie de développement des modèles RNAG

La méthodologie et le processus de développement de la structure hybride RNAG pour la conception des modèles de formulation des bétons et les modèles de prédiction de la résistance à la compression des bétons à base de pouzzolane naturelle ou des cendres volantes est représentée dans la figure 4.1. Son organisation se fait suivant quatre phases principales :

- la collecte des données déjà présentées dans le chapitre 3.
- l'architecture et la détermination des paramètres d'apprentissage du réseau de neurones (RN).
- l'optimisation de l'architecture proposée par l'application d'un algorithme génétique (AG).
- le choix et l'évaluation de la performance du modèle hybride optimisé (RNAG).

Le développement, l'implémentation et la simulation de ces modèles ont été effectuées à l'aide des fonctions de Toolbox neural networks et algorithmes génétiques du logiciel MATLAB R2014a.

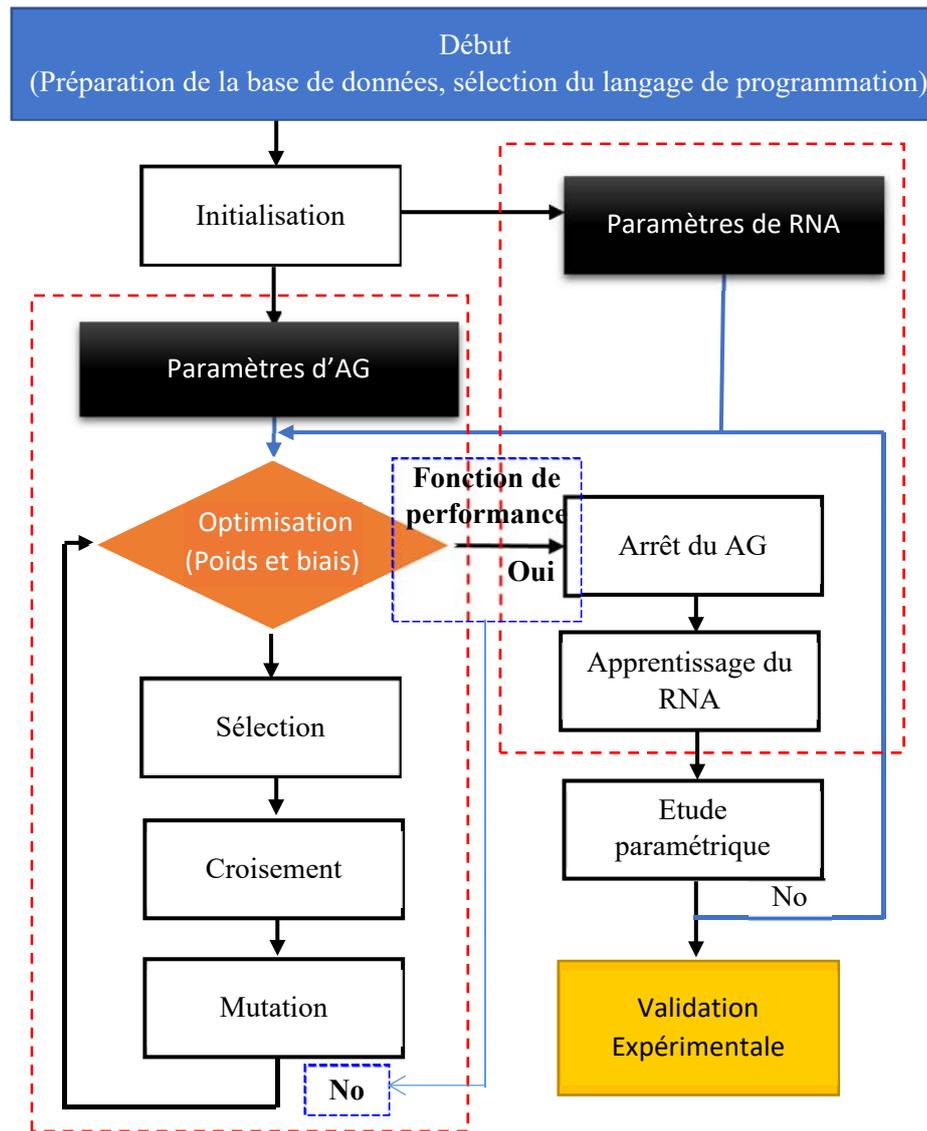


Figure 4.1 – Méthodologie suivie pour le développement du modèle hybride RNAG (Rebouh et al., 2017)

4.3 Développement de la structure hybride RNAG

Dans la plupart des applications des réseaux de neurones, l'architecture du réseau, c.à.d le nombre d'unités ainsi que leurs connexions, est fixée au départ. Ce choix est souvent dicté par des heuristiques qualitatives du type : "le nombre d'unités cachées augmente avec la difficulté du problème" (Houssou, 2005). L'approche utilisée dans le développement du système RNGA est basée sur les algorithmes génétiques pour optimiser les poids de connexion et les biais de l'architecture du réseau de neurone. Le processus de développement du RNGA est divisé en 3 parties :

- Partie réseaux de neurone ;
- Partie Algorithme génétique (hybridation) ;
- Partie validation (critère d'arrêt).

4.3.1 Détermination des paramètres du RNA

Divers facteurs peuvent affecter l'exécution d'un réseau de neurones. Ces facteurs sont liés à la topologie du réseau d'une part et aux paramètres d'apprentissage d'autre part. Les paramètres reliés à la topologie du réseau incluent le nombre de paramètres d'entrées et de sortie, le nombre de couches cachées et le nombre de neurones dans chaque couche cachée. Les paramètres d'apprentissages concernent principalement le choix de l'algorithme d'apprentissage, la fonction de performance, la fonction de transfert entre les couches du réseau, l'erreur maximale et le nombre de cycles d'apprentissage permis.

Les étapes de mise en œuvre d'un réseau de neurones pour la prédiction ou le classement sont :

1. Identification des données d'entrée et de sortie ;
2. Normalisation des données ;
3. Constitution d'un réseau avec une topologie adaptée ;
4. Apprentissage du réseau ;
5. Test du réseau ;
6. Application du modèle généré par l'apprentissage ;
7. Dé-normalisation des données en sortie.

Les étapes de 1 à 7 sont traduites sous le langage Matlab pour créer un réseau de neurones constitué d'une couche d'entrée avec 6 neurones, deux couches cachées avec 7 et 5 neurones respectivement, et une couche de sortie (Figure 4.2).

```

    % INITIALIZE THE NEURAL NETWORK PROBLEM %

%%Identification des données en entrée et en sortie%%
load BaseDeDonne.dat; x= BaseDeDonne(:, :);
[nligne ncol] =size(x);
p=x(:,1:6);t=x(:,7); %% p input et le t est le output%%

%%Normalisation de ces données%%
p=p';t=t';
[pn,ps]=mapminmax(p);
[tn,ts]=mapminmax(t);

'%% Constitution d'un réseau avec une topologie adaptée
% number of neurons
L1 = 7;
L2 = 5;
%% Création du Réseau de Neurone %%
net=init(net);
net = newff(pn,tn, [L1 L2], {'tansig' 'tansig'});
%% 'tansig' représente la fonction de Transfer%%

% Fonction et taux de devisions des données %
net.divideFcn = 'dividerand';
net.divideParam.trainRatio = 0.7;
net.divideParam.valRatio = 0.15;
net.divideParam.testRatio = 0.15;

% Fonction de performance %
net.performFcn = 'mse';
net.trainFcn='trainlm';
net.trainParam.epochs = 1000; % Cycles d'apprentissage
(Itérations)
net.trainParam.goal = 1e-4; % Erreur désirée
net.trainParam.show = 10;

%%Apprentissage du réseau%%
[net,tr]=train(net,pn,tn);
%Simulation après apprentissage
annew = sim(net,pn);

% Dé-normalisation des données en sortie
at=mapminmax('reverse',annew,ts);

```

Figure 4.2 – Code Matlab pour la Création de réseau de neurone

4.3.2 Hybridation AG et RNA

Comme déjà montré dans le chapitre 01, le développement des réseaux de neurones avec l'algorithme de rétropropagation, présente plusieurs limites telles que sa sensibilité aux minima locaux et sa possibilité de divergence.

Pour cet effet, une nouvelle structure basée sur l'intégration d'un AG aux RNAs a été développée. Cette structure est appliquée pour optimiser les poids de connexion et les seuils au niveau de chaque neurone de l'architecture du réseau de neurones proposée. Avant d'appliquer les opérateurs de l'algorithme génétique, l'architecture proposée doit être encodée sous forme d'un chromosome.

Il existe plusieurs types d'encodage de l'architecture du réseau de neurone (voir chapitre 1), un encodage réel a été choisi pour éviter le problème de taille en cas de l'encodage binaire (Figure 4.3) car l'utilisation de longues chaînes de bits est inévitable ce qui rend la convergence lente et parfois même inefficace (Alajmi, 2014). Les processus d'optimisation des poids de connexions et les biais de l'architecture sont les suivant :

1. Encodage de l'architecture du réseau adopté ;
2. Génération de la population initiale présentée par un ensemble de solution (chromosome) ;
3. Calcul de la valeur de performance de chaque chromosome (Architecture du réseau) ;
4. Choix des meilleurs chromosomes (parents) selon le critère de la sélection choisie ;
5. Application des opérateurs des algorithmes génétiques ; le croisement et mutation ;
6. Répéter de les étapes de 2 à 5 jusqu' à l'atténuation du critère d'arrêt imposé.

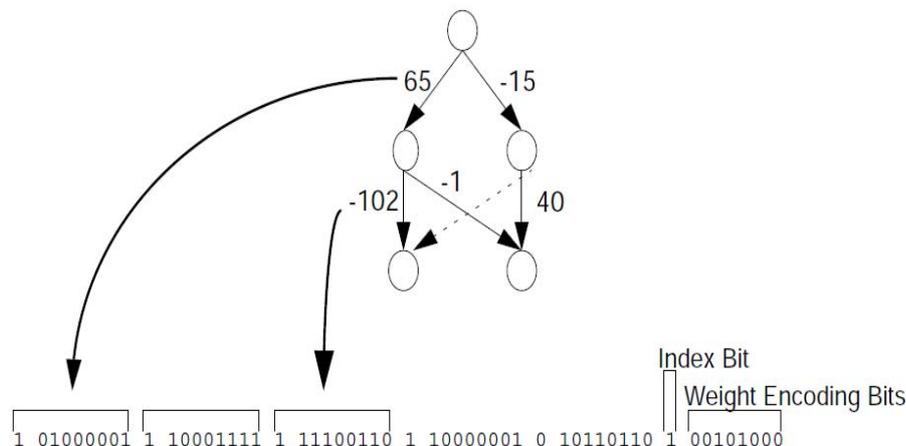


Figure 4.3 – Encodage binaire (Koehn, 1994)

- **Encodage réel :**

Ce type d'encodage transforme le réseau de neurones en un vecteur de valeurs réelles (chromosomes). Plusieurs applications utilisent ce type d'encodage. Les opérateurs génétiques (sélection, croisement et mutation) sont appliqués sur ces vecteurs (Figure 4.4).

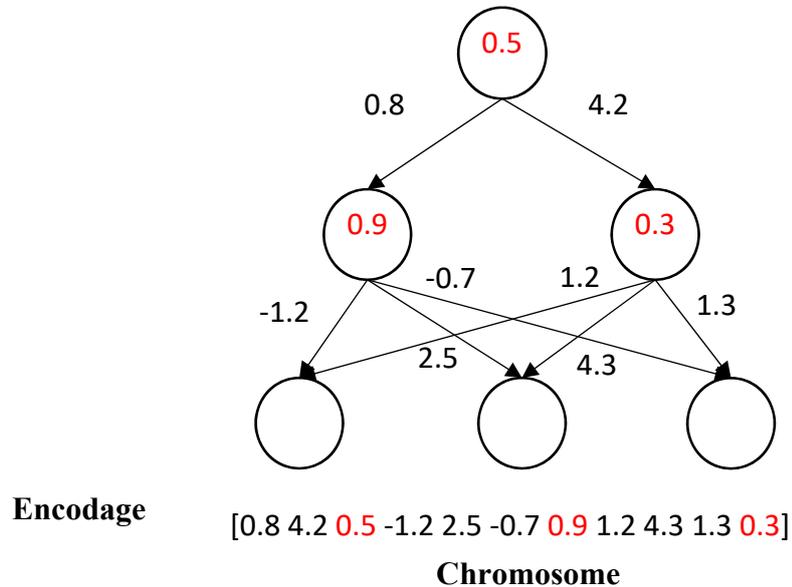


Figure 4.4 – Encodage réel des poids et les biais d'un réseau de neurone

La figure 4.5 présente le code Matlab développé dans ce travail qui permet d'optimiser les poids de connexion et les seuils initiaux de l'architecture du réseau de neurones choisi. Pour le bon fonctionnement du code il faut que son exécution soit effectuée sous Matlab 2014a, ou sous une version plus récente.

Pour les réseaux de neurones, les paramètres choisis tels que le nombre de couches, la fonction de Transfer, l'algorithme d'apprentissage, la fonction de performance...etc. sont illustrés dans la figure 4.2. Le nombre de générations, la taille de population, les fonctions des différents opérateurs génétiques...etc. (Figure 4.5) ne sont pas fixes. A cet effet, le concepteur doit modifier, ajouter ou supprimer ces paramètres pour trouver la combinaison optimale.

```

%%Identification des données en entrée et en sortie%%
load BaseDeDonne.dat; x= BaseDeDonne(:, :);
[nligne ncol] =size(x);
p=x(:,1:6);t=x(:,7); %% 'p' input et le 't' est le output%%

%%Normalisation de ces données%%
p=p';t=t';
[pn,ps]=mapminmax(p);
[tn,ts]=mapminmax(t);

%%Constitution d'un réseau avec une topologie adaptée%%
% number of neurons
L1 = 7;
%L2 = 5
% création du réseau de neurone
inputs = pn;
targets = tn;
net = feedforwardnet(S1);
%configuration du réseau de neurone
net = configure(net, inputs, targets);

% calcul du MSE (mean square error)
h = @(x) mse (x,net,inputs,targets); %fonction de
performance
R=size(pn,1);
S3=size(tn,1);

%Longueur du chromosome S
S=R*L1+L1*S3+L1+S3; % (Encodage de chromosome)
%S=R*L1+L1*L2+L2*S3+L1+L2+S3; cas de 2 couches cachés
gen = 50; %% nombre de génération
Pop = 100; %% taille de populations

% Algorithme génétique avec les options désirées
ga_opts = gaoptimset('TolFun',1e-8,...
'MutationFcn',{@mutationuniform,0.1},'CrossoverFraction',0.9
,...
'CrossoverFcn',@crossoverheuristic,'Generations',gen,...
'PopulationSize',Pop,'PopulationType','doubleVector',...
'SelectionFcn',@selectiontournament,...
'display','iter');

%lancement du l'algorithme génétique
[x_ga_opt, err_ga] = ga(h, S, ga_opts);

```

Figure 4.5 – Code Matlab pour l'hybridation RNAG.

4.4 Modèles proposés de formulation et de prévision de la résistance

En utilisant la structure hybride RNAG développée, 3 modèles différents ont été élaborés dont deux pour la prévision de la résistance à la compression et un modèle pour la formulation des bétons contenant des cendres volantes.

4.4.1 Résistance à la compression du béton

La résistance à la compression du béton est généralement considérée comme la plus importante propriété dans de nombreux cas pratiques. La résistance à la compression projette généralement une image globale sur la qualité d'un béton puisqu'elle est directement reliée à la structure de la pâte de ciment hydraté.

Pour les bétons ordinaires de masse volumique allant de 2000 à 2600 kg/m³, la norme NF EN 206-1 distingue 16 classes différentes (Tableau 4.1)

Tableau 4. 1 – Différentes classes de béton et leurs utilisations

Type de béton	Classe de la résistance	Exemples
Béton ordinaire	C8/10	Usage décoratif seulement
	C12/15	Usage décoratif seulement
	C16/20	Béton de propreté
	C20/25	Fondations légères (semelle filante ou isolée) Dallage sur vide sanitaire
	C25/30	Dalle/plancher interne à une maison Dalle extérieure classique et dallage sur terre-plein, Voile intérieur ou extérieur.
	C30/37	Dallage sans contraintes particulières, avec emploi de fibres structurelles
	C35/45 C40/50	Béton pour hangar agricole (élevage, fumier...)
Béton à hautes performances	C45/55	Élément soumis à des efforts importants (poutres de très grande portée ou plancher très chargé)
	C50/60	Béton haute résistance
	C55/67	Béton haute résistance
Béton à très hautes performances	C60/75	Béton haute résistance
	C70/85	Béton haute résistance
	C80/95	Béton haute résistance
	C90/105 C100/115	Béton haute résistance

4.4.2 Ouvrabilité du béton

La résistance d'un béton donné est très affectée par le degré de compacité. Il est important que la consistance du béton soit ajustée de façon que le béton puisse être facilement transporté, mis en place, vibré et fini sans qu'il y ait de ségrégation.

L'ouvrabilité est une qualité essentielle du béton. Un béton qui peut être mis en place puis serré correctement est considéré comme étant une bonne maniabilité. La définition de la maniabilité donnée par ACI116R-90 est la suivantes : « propriété d'un mortier ou d'un béton fraîchement malaxé qui définit la facilité et l'homogénéité à être malaxé, mis en place, serré et fini » (Neville, 1995).

L'ouvrabilité ou la maniabilité peut s'apprécier de diverses façons et particulièrement par les mesures de plasticité (Figure 4.6), il existe plusieurs méthodes permettant la mesure de l'ouvrabilité, la méthode la plus fréquemment utilisé est l'essai d'*Affaissement au cône d'Abrams* (Dreux, 1982).

Les mesures sont évidemment quelque peu dispersées et il ne faut pas accorder à cet essai un caractère trop rigoureux, mais on peut admettre qu'il caractérise bien la consistance d'un béton et permet le classement approximatif indiqué au tableau 4.2 (Dreux, 1982).

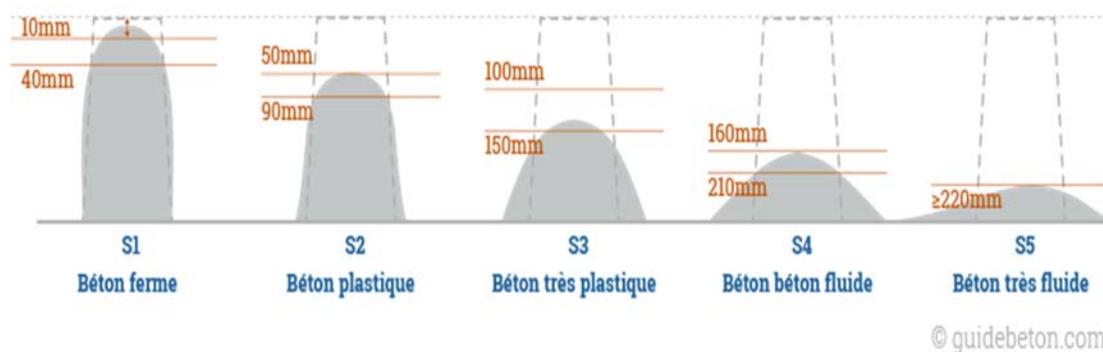


Figure 4.6 – Différents classes de l'ouvrabilité
(<http://www.guidebeton.com/classes-consistance-beton>).

Tableau 4.2 – Classification de la consistance en fonction de l’affaissement au cône
(Dreux, 1982).

Classe	Affaissement	Définition	Exemple
S1	de 10 à 40 mm	Béton ferme, construction sur une pente forte	Escalier, accès en pente, béton de voirie
S2	de 50 à 90 mm	Béton plastique, construction sur une pente faible	Dalle pleine, ouvrage d’art
S3	de 100 à 150 mm	Béton très plastique, construction sur une surface plane	Dalle, fondation
S4	de 160 à 210 mm	Construction sur une surface plane	Dalle, fondation, voile
S5	≥ 220 mm	Béton fluide, construction sur une surface plane, absence de système de vibration	Dalle, fondation

4.5 Définition des entrées et sorties des modèles

Après avoir terminé la préparation des données, l’ensemble des données d’entrées et de sorties (input /output) des modèles proposés est présentée dans le tableau 4.3.

Le choix des paramètres d’entrées et de sorties dépend de la disponibilité des données dans le but de développer des modèles simples, faciles et plus pratiques pour la conception des bétons. Cette étape est très importante, elle est considérée comme un processus décisif dans le choix de la meilleure architecture RNA du modèle.

Tous les paramètres d’input et d’output des modèles présentés dans le tableau 4.3 sont très faciles à identifier. En plus, pour les modèles M2 et M3, on a ajouté un nouveau paramètre pour désigner la classe des cendres volantes, présenté par l’indice D.

Tableau 4.3 – Paramètre Input et output des modèles proposés

Modèle	Input	output
Prévision de la résistance à la compression pour des bétons aux pouzzolanes naturelle « M1 »	<ul style="list-style-type: none"> ➤ Liant (kg/m³) ➤ Eau/ liant ➤ Taux de la pouzzolane (%) ➤ Superplastifiant (%) ➤ Gravier (kg/m³) ➤ Sable (kg/m³) ➤ Age (Jour) 	<ul style="list-style-type: none"> • Résistance à la compression (MPa)
Prévision de la résistance à la compression pour des bétons aux cendre volante « M2 »	<ul style="list-style-type: none"> ➤ Liant (kg/m³) ➤ Eau/ liant ➤ Taux de Cendre volante (%) ➤ Indice D ➤ Gravier (kg/m³) ➤ Sable (kg/m³) ➤ Age (Jour) 	<ul style="list-style-type: none"> • Résistance à la compression (MPa)
Formulation des bétons contenant de la cendre volante « M3 ».	<ul style="list-style-type: none"> • Résistance à la compression (MPa) • Ouvrabilité (mm) • Taux de Cendre volante (%) • Indice D • Rapport Gravier /Granulats • Age (Jour) 	<ul style="list-style-type: none"> • Liant (kg/m³) • Eau/ liant • Granulats (kg/m³)

🚧 Identification de l'indice D

La norme ASTM 618 donne la classification des cendres volantes selon le contenant d'oxyde de calcium (**CaO**) et la somme des oxydes (**SiO₂+Al₂O₃+Fe₂O₃**).

La norme ASTM 618, catégorise les cendres volantes en deux catégories, soient la Classe F (silico-alumineuse) et la Classe C (sulfo-calciq) selon les spécifications suivantes :

- La somme des composants chimiques : SiO₂, Al₂O₃ et Fe₂O₃ doit être supérieur à 70% pour la classe F et 50% pour la classe C.
- La teneur en CaO doit être inférieure à 8 % pour la cendre volante classe F et supérieure à 8% pour la classe C.

La figure 4.7 montre la relation entre le **CaO** et la somme de **SiO₂+Al₂O₃+Fe₂O₃** de 110 types de cendres volantes de l'Amérique du nord (Thomas, 2007).

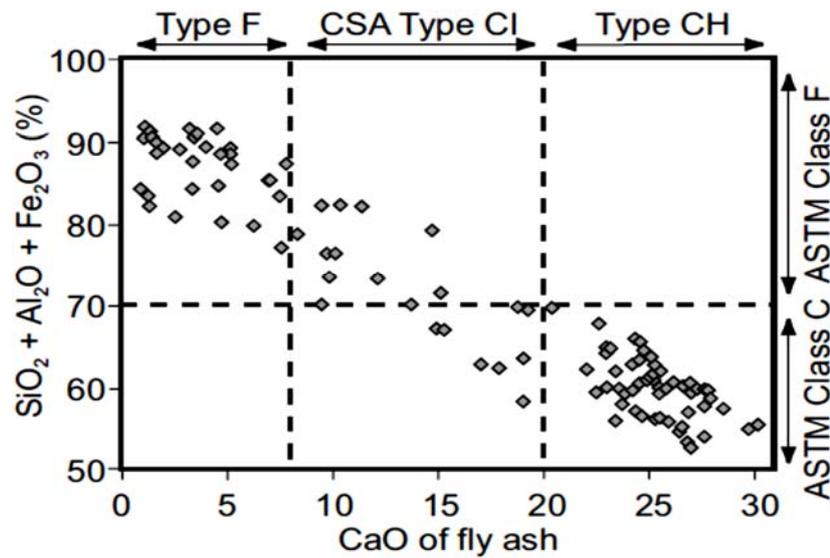


Figure 4.7 – Relation entre CaO et la somme SiO₂+Al₂O₃+Fe₂O₃ de 110 types de CV de l’Amérique de nord (Thomas, 2007)

Pour le modèle de prévision **M2** proposé, le type des cendres volantes est pris en considération par le biais du paramètre d’input « D ». Le facteur D est le rapport de la somme des oxydes (SiO₂+Al₂O₃+Fe₂O₃) sur le taux de CaO (Eq. 4.1)

$$Indice D = \frac{SiO_2 + Al_2O_3 + Fe_2O_3}{CaO} \tag{4.1}$$

Le rapport D est proposé dans le but de donner une meilleure identification des cendres volantes. Afin que le modèle **M2** peut être utilisé quelle que soit la classe des cendres volantes (C ou F). La figure 4.8 montre les valeurs limites de l’indice D qui désigne la classe des cendres volantes à partir des résultats représentés par Thomas (2007) dans la Figure 4.8.

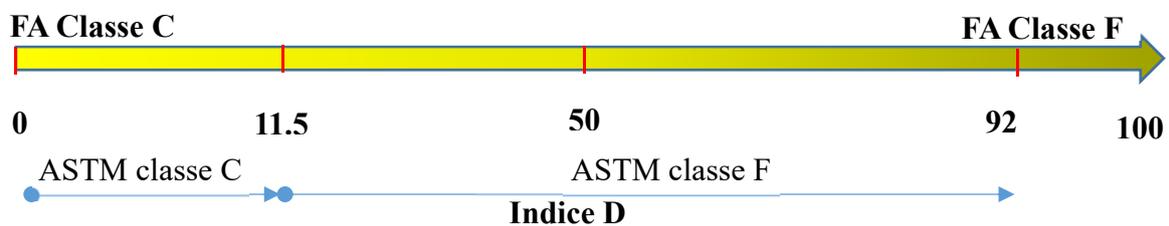


Figure 4.8 – Identification de l’Indice D selon ASTM 618.

4.6 Développement du modèle M1 pour le béton à la pouzzolane naturelle

Le premier modèle développé dans ce travail en utilisant la structure hybride RNAG est le modèle de prévision de la résistance à la compression des bétons aux pouzzolanes naturelles « **M1** ». La base de données utilisée pour la conception de ce modèle de prévision est présentée dans le chapitre 3.

Le nombre de couches cachées a été choisi afin de rendre le réseau aussi simple que possible, et ainsi, d'éviter de prolonger le temps d'apprentissage. Le nombre des neurones dans la couche cachée a été modifié pour explorer son effet sur l'exécution du réseau.

Après plusieurs essais, l'architecture choisie pour le modèle **M1** est constituée d'une couche d'entrées avec 7 neurones (le liant, le rapport Eau/Liant, le taux de la pouzzolane naturelle **PN**, le dosage du superplastifiant, le gravier, le sable et l'âge), une seule couche cachée avec 5 neurones et une couche de sortie avec un seul neurone présentée par la résistance à la compression (Figure 4.9).

L'ensemble des paramètres choisis pour l'apprentissage du réseau est montré dans le tableau 4.4.

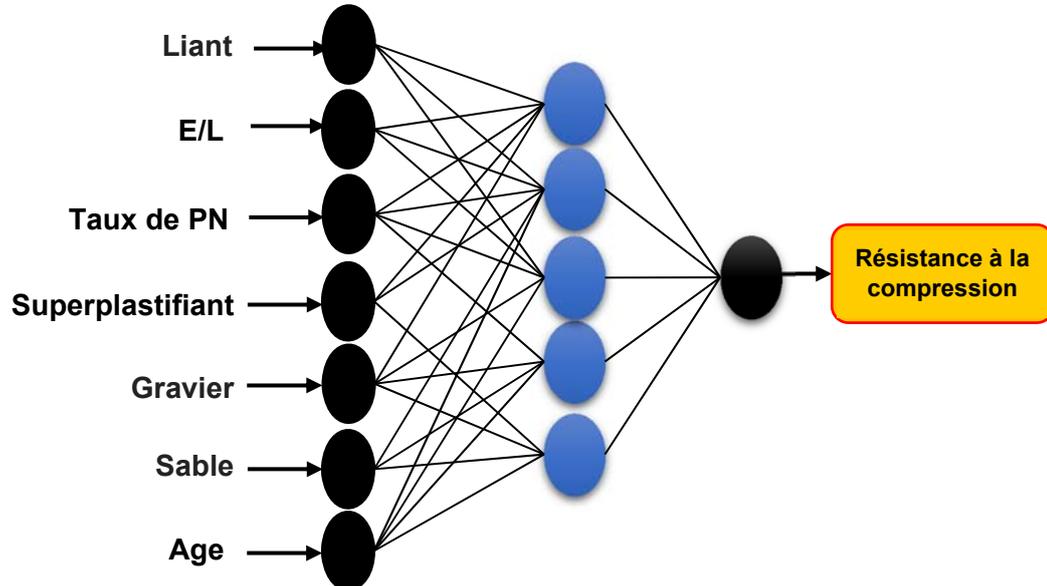


Figure 4.9 – Architecture du modèle de prévision « **M1** ».

Tableau 4.4 – Les paramètres utilisées pour l'apprentissage du RNA

Parameter RNA	Valeur et Désignation dans le MATLAB
Train Function	'trainlm' (Levenberg Marquardt)
Transfer Function	'tansig' (no linear function).
Performance function	'Mse' (Mean square error).
Error after learning	0.001
Divide Function	'dividerand'
Net.divideParam.trainRatio	0.70
Net.divideParam.valRatio	0.20
Net.divideParam.testRatio	0.10
Train epochs	1000

4.6.1 Mécanisme d'optimisation de l'architecture du modèle M1

4.6.1.1 Encodage et génération de la population initiale

Après avoir choisi l'architecture du modèle **M1** (Figure 4.9), on passe à la phase d'optimisation des poids et les seuils initiaux de l'architecture choisi en appliquant les étapes des algorithmes génétiques ; encodage de l'architecture ensuite, une population initiale d'une taille prédéfinie a été générée formées de plusieurs chromosomes.

Les meilleurs chromosomes ont plus de chance d'être sélectionnés pour la reproduction selon un critère de sélection choisi

Les opérateurs génétiques d'évolution sont appliqués sur ces chromosomes comme représenté dans les figures 4.10, 4.11 et 4.12

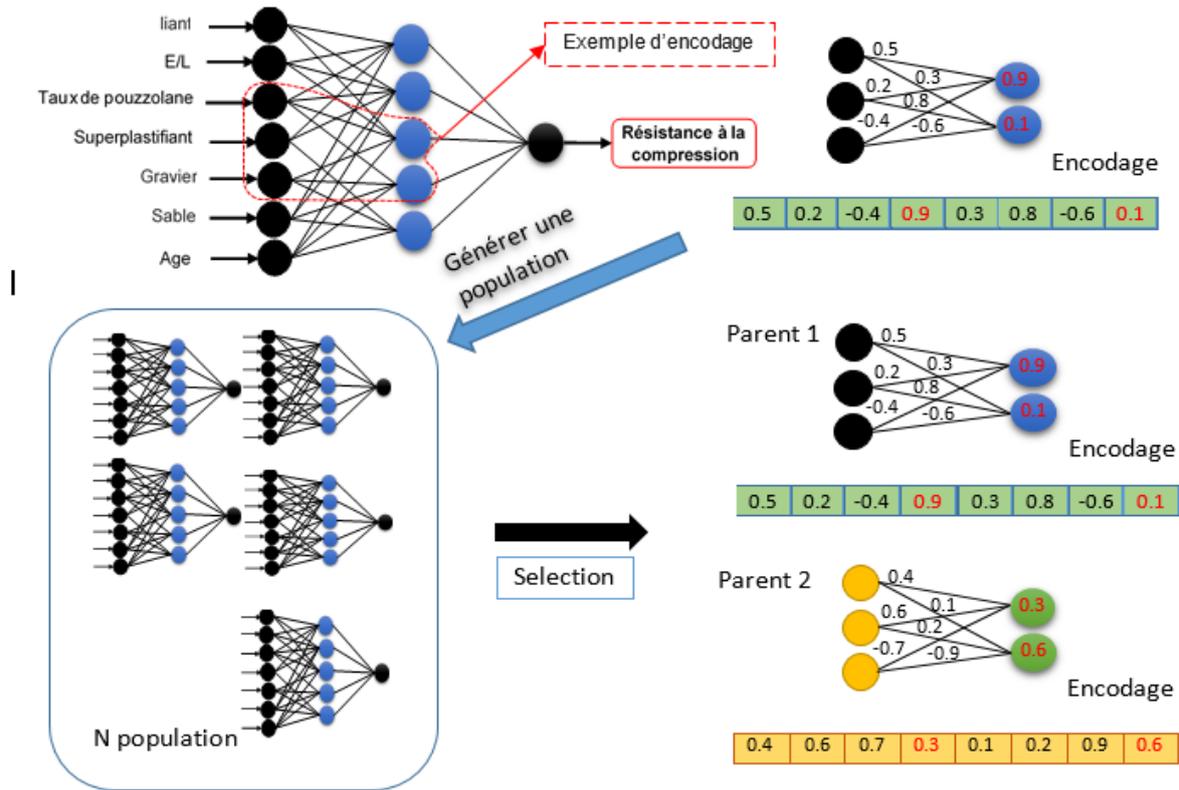


Figure 4.10 – Encodage de l’architecture du RN (Rebouh et al., 2017)

4.6.1.2 Application des opérateurs d’AG

Le premier opérateur d’évolution est *le croisement* qui a été appliqué simultanément pour le croisement des poids et des seuils (neurones) (Figure 4.11). Dans ce croisement, pour chacune des différentes combinaisons de deux chromosomes parents, les poids et les seuils ont été choisis aléatoirement pour générer deux chromosomes enfants.

Le deuxième opérateur d’évolution est *la mutation* qui a consisté à inverser aléatoirement les valeurs de poids de connexions et de seuils de chacun des chromosomes enfants pour générer de meilleurs chromosomes (Figure 4.12).

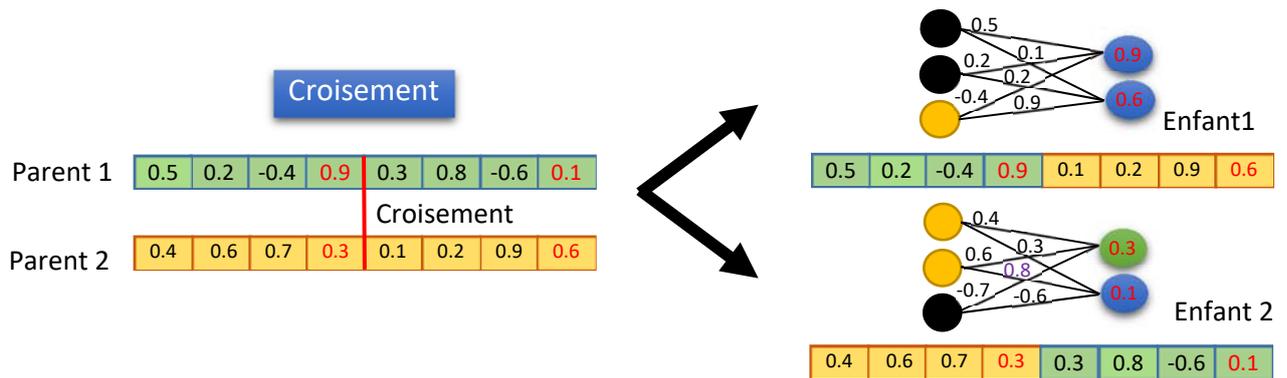


Figure 4.11 – Operateur de croisement (Rebouh et al., 2017).

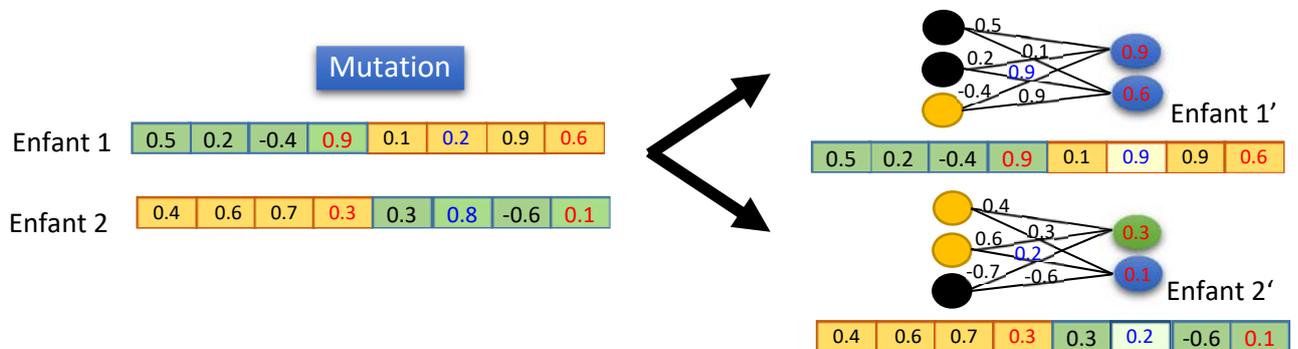


Figure 4.12 – Operateur de Mutation (Rebouh et al., 2017).

4.6.1.3 Fonctions d'évaluation

La génération d'une nouvelle configuration de poids de connexion et des seuils est un processus itératif, dans lequel les solutions mauvaises ont été éliminées par la fonction d'évaluation 'MSE' « Mean Squared Error» comme fonction fitness. Chaque nouvelle configuration du réseau RN a été ensuite entraînée en utilisant l'algorithme de Rétropropagation du gradient pour modifier les poids de connexion et les seuils par la même fonction de performance MSE Cette fonction calcule l'erreur moyenne pondérée par le carré des écarts entre les prévisions et les observations en estimant la magnitude de l'erreur de la prévision (Eq. 4.2) :

$$MSE = \frac{1}{N} \sum_{k=1}^N ((t(k) - a(k))^2) \tag{4.2}$$

L'ensemble des paramètres choisis de l'algorithme génétique est représenté dans le tableau 4.5.

Tableau 4.5 – Paramètres utilisés pour AG.

Paramètres d'AG	Valeur et Désignation dans le MATLAB
Population size	50
Generation number	10
Mutation function	@mutationuniform
Crossover Function	@crossoverheuristic
Selection Function	@selectiontournament
Crossover Fraction	0.2
Termination tolerance on fitness function value	'TolFun'

4.6.2 Evaluation de la performance du modèle hybride RNAG

La quatrième phase est l'étape décisive, elle représente le critère d'arrêt de l'optimisation du modèle RNAG développé. En l'occurrence, une analyse de sensibilité a été menée d'abord en comparant le modèle hybride RNAG à un modèle RN seul en utilisant la même architecture.

La comparaison a été faite en terme de différents indicateurs de performance (ou d'erreur) notamment **MSE** (Mean Squar Error), **RMSE** (Root Mean Square Error), **MAPE** (Mean Absolute Percentage Error) et du coefficient de détermination (R^2). La valeur de **RMSE** (Eq. 4.3) décrit la grandeur moyenne des erreurs en donnant plus de poids à des erreurs importantes, tandis que la valeur du **MAPE** (Eq. 4.4) ne peut s'appliquer qu'à des valeurs strictement positives et permet une mesure de la précision de la prédiction du modèle de prévision. Le coefficient de détermination R^2 (Eq. 4.5) quant à lui mesure le degré d'association entre les valeurs observées et les valeurs prédites pour justifier l'importance de la relation étudiée.

Généralement des valeurs inférieures des termes d'erreurs et une valeur élevée de R^2 indique une bonne performance de la prédiction d'un modèle. Le tableau 4.6 présente les différentes valeurs de ces indicateurs conformément à l'apprentissage des deux modèles développés.

$$RMSE = \sqrt{\left(\frac{1}{p}\right) \sum_j (t_j - o_j)^2} \quad (4.3)$$

$$MAPE = \frac{1}{p} \sum_j \left(\left| \frac{o_j - t_j}{o_j} \right| * 100 \right) \quad (4.4)$$

$$R^2 = 1 - \left(\frac{\sum_j (t_j - o_j)^2}{\sum_j (o_j)^2} \right) \quad (4.5)$$

Où :

t_j est la valeur cible de « j^{th} » échantillon, « O_j » est la valeur de sortie de « j^{th} » échantillon, et « p » est le nombre des échantillons.

Tableau 4.6 – Comparaison entre le RN et le RNAG

Model	MSE	RMSE	MAPE	R Apprentissage	R ² Expérimentale	Nombre d'itérations
RN	12.01	5.39	2.64	0.96	0.85	922
RNAG	8.13	3.50	2.18	0.97	0.93	131

D'après le tableau 4.6, il est clairement montré que le modèle hybride RNAG est plus performant et plus rapide que le RN seul. En comparant les valeurs de l'erreur RMSE, le modèle hybride RNAG a donné une valeur inférieure que le modèle RN avec 3,50 et 5,39 respectivement. La valeur du RMSE décrit la grandeur moyenne des erreurs en donnant plus de poids à des erreurs importantes. Des valeurs très faibles de RMSE et MAPE indiquent une meilleure performance du modèle (Kisi et al, 2013). Donc, les résultats statistiques résumés dans le tableau 4.6 confirment la performance du modèle hybride RNAG par rapport au modèle RNA.

Le coefficient de corrélation «**R**» présenté dans la figure 4.13 et le coefficient de détermination «**R²**» (Eq. 4.5), mesurent le degré d'association entre les valeurs observées (expérimentales) et les valeurs prédites par le modèle. Pour une association parfaite entre les valeurs observées et les valeurs prévues, le $R^2 = 1$. Le modèle hybride RNAG a convergé vers les bons résultats avec un $R^2 = 0.93$ au-delà de la 131^{ème} itération. Par contre, pour le modèle

de prévision basé sur la technique des RNAs, la convergence est obtenue après la 922^{ème} itération avec un coefficient $R^2 = 0.85$ qui est nettement inférieur à celui du modèle hybride. Cela indique la robustesse, la fiabilité et la rapidité du modèle RNAG.

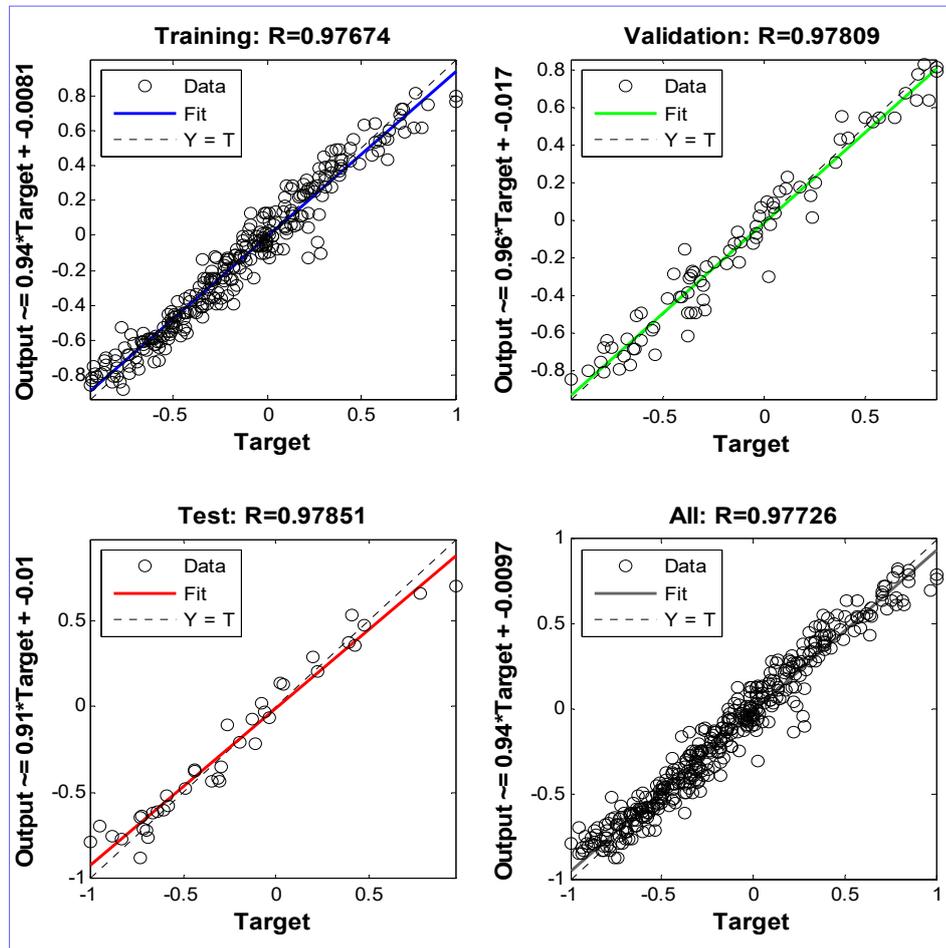


Figure 4.13 – Corrélation obtenus pour les différentes phases (Apprentissage, Validation et Teste) de RN optimisé.

Cependant, à cause de la complexité du phénomène étudié, l'auto-validation d'un modèle RN après son développement basé généralement sur les critères de la minimisation de l'erreur et la maximisation de la corrélation est insuffisante. En conséquence un nombre important de modèles de prévision avec des coefficients de corrélation « $R > 90$ », et des indicateurs d'erreurs acceptables ont été obtenus ce qui complique le choix du bon modèle.

Donc, pour justifier le choix du modèle RNAG et pour prouver sa robustesse et sa fiabilité par rapport à d'autres modèles, on a jugé utile de confronter les résultats obtenus du modèle avec ceux d'autres modèles existant dans la littérature d'une part, et de les comparer

aussi avec de nouveaux résultats expérimentaux obtenus par la réalisation d'un programme expérimental au laboratoire d'autre part.

4.7 Développement des Modèles pour le béton aux cendres volantes

Une fois que le système hybride RNAG a montré une performance plus efficace que le RNA seul, la structure RNAG est utilisé pour le développement des modèles de prévision et de formulation des bétons aux cendres volantes «M2» et «M3» respectivement.

4.7.1 Modèle de prévision de la résistance à la compression M2

Une architecture simple à une seule couche cachée mais cette fois avec 6 neurones cachés a été proposé (Figure 4.14) pour le Modèle de prévision de la résistance à la compression «M2». L'ensemble des paramètres choisis pour l'apprentissage du réseau et pour l'algorithme génétique sont représenté dans les tableaux 4.7 et 4.8 respectivement.

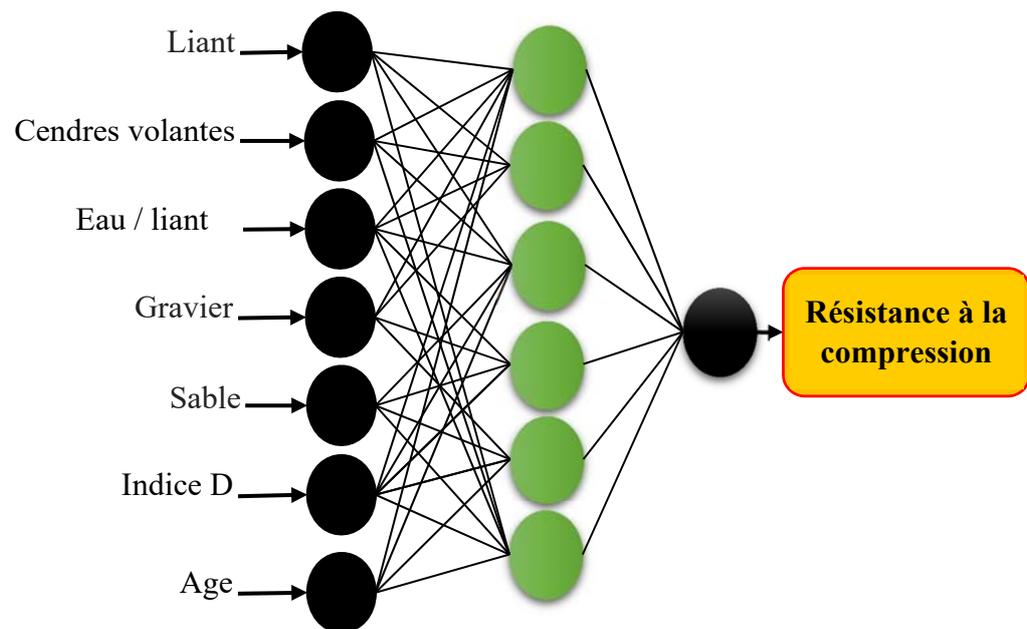


Figure 4.14 – Architecture du modèle de prévision « M2 ».

Tableau 4.7 – Les paramètres utilisées pour l'apprentissage du RNA

Parameters de RNA	Valeur et désignation dans le MATLAB
Train function	trainlm (Levenberg–Marquardt)
Transfer function	tansig (no linear function).
Number of Neurons	06
Performance function	Mse (Mean square error).
Error after learning	0.001
Divide function	Dividerand
Net.divideParam.trainRatio	0.80
Net.divideParam.valRatio	0.15
Net.divideParam.testRatio	0.05
Train epochs	1000

Tableau 4.8 – Paramètres utilisés pour AG.

Parameters d'AG	Valeur et désignation dans le MATLAB
Population size	70
Generation number	10
Mutation function	@mutationuniform
Crossover function	@crossoverheuristic
Selection function	@selectiontournament
Crossover fraction	0.5
Termination tolerance on fitness function value	TolFun

4.7.2 Modèle de formulation des bétons aux cendres volantes M3

Le modèle **M3** est un modèle de formulation des bétons à base de cendres volantes, le modèle permet d'optimiser la composition du béton vis-à-vis de deux propriétés essentielles à l'état frais et à l'état durci : l'ouvrabilité et la résistance à la compression respectivement, c.à.d. formuler le béton à partir des propriétés bien définies. Il s'agit d'un problème inverse de la prévision, où le développement du modèle **M3** devient très compliqué par rapport au Modèle de prévision **M2**.

La base de données utilisée pour le développement du modèle **M3** est la même base de données utilisée durant le développement du modèle **M2**, l'ensemble des paramètres d'entrées et de sorties sont présentés dans le tableau 4.3.

La complexité du problème d'optimisation du mélange de béton ainsi que la topologie d'architecture du réseau de neurones avec plusieurs sorties à la fois rend le choix de l'architecture optimale très difficile.

Après avoir effectué plusieurs essais d'apprentissage avec un réseau de neurone d'une seule couche cachée en utilisant la structure hybride RNAG, on n'a pas pu trouver de bons résultats, ce qui nous a conduits à choisir des réseaux à deux couches cachées.

L'architecture proposée pour le modèle de formulation **M3** est illustrée dans la figure 4.15. Elle est composée de 2 couches cachées avec 7 neurones dans la première couche et 5 neurones dans la deuxième couche.

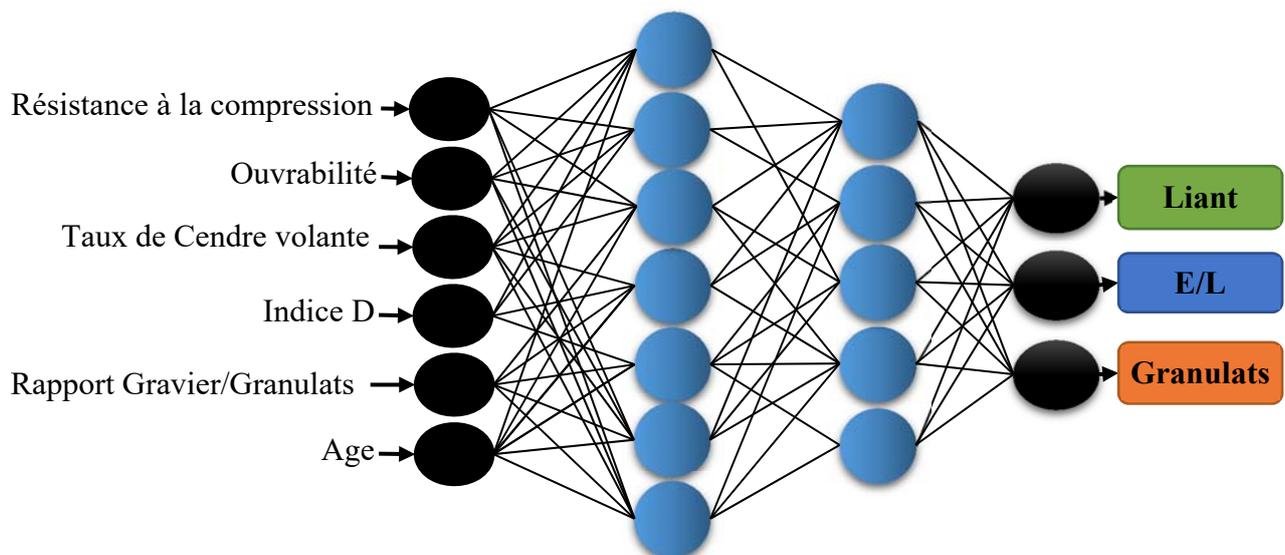


Figure 4.15 – Architecture du modèle de prévision « **M3** ».

L'ensemble des paramètres choisis pour l'apprentissage du réseau est résumé dans le tableau 4.9, et celui de l'algorithme génétique est représenté dans le tableau 4.10.

Tableau 4.9 Les paramètres utilisées pour l'apprentissage du RNA

Parameters de RNA	Valeur et désignation dans le MATLAB
Train function	trainlm (Levenberg–Marquardt)
Transfer function	tansig (no linear function).
Number of Neurons	12
Performance function	Mse (mean square error).
Error after learning	0.001
Divide function	Dividerand
Net.divideParam.trainRatio	0.90
Net.divideParam.valRatio	0.05
Net.divideParam.testRatio	0.05
Train epochs	1000

Tableau 4.10 – Paramètres utilise pour AG.

Parameters d'AG	Valeur et désignation dans le MATLAB
Population size	70
Generation number	10
Mutation function	@mutationuniform
Crossover function	@crossoverheuristic
Selection function	@selectiontournament
Crossover fraction	0.2
Termination tolerance on fitness function value	TolFun

4.8 Interface adoptée pour les modèles développés

Pour que les modèles développés dans la présente étude soient utiles et pratiques, et pour faciliter leurs utilisations, un prototype d'un logiciel de prévision et de formulation des bétons ordinaire aux ajouts cimentaires a été élaboré. L'interface graphique a été implémentée sur la base du langage de programmation DELPHI XE7 (DELPHI, 2014).

L'interface graphique proposée enveloppe les trois modèles, l'utilisateur peut choisir entre la prévision de la résistance à la compression de béton (modèles **M1** et **M2**) ou la formulation des bétons contenant des cendres volantes (modèle **M3**).

Le logiciel élaboré est nommé « **Concrete Mix Software** », le démarrage du système est un fichier exécutable fonctionne sur Windows, la page d'Accueil du logiciel s'affiche comme le montre la figure 4.16.

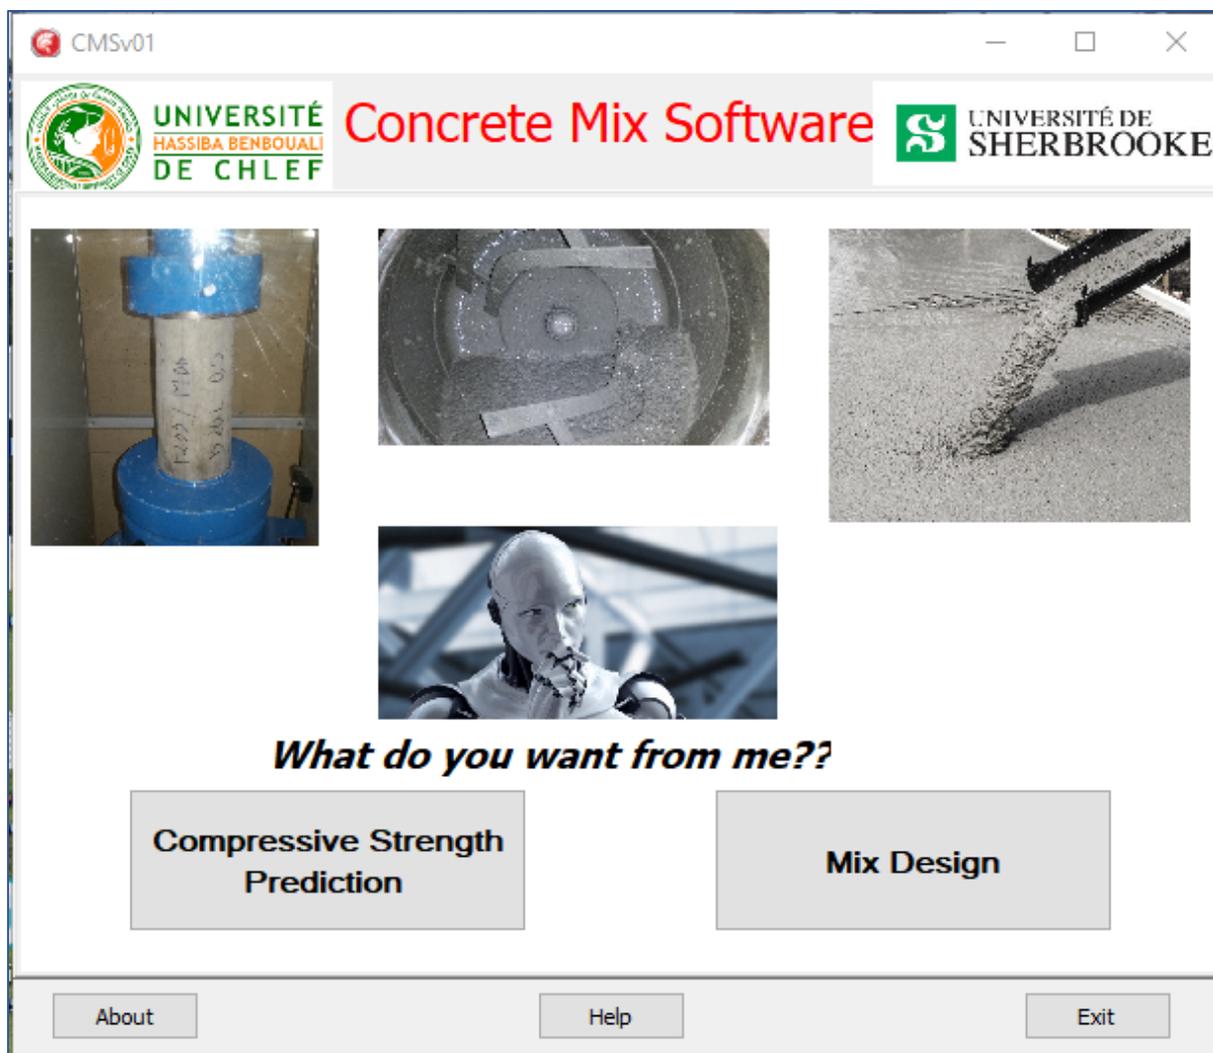


Figure 4.16 – Interface graphique du logiciel CMSv01.

Après que l'utilisateur fait son choix, une deuxième fenêtre va s'apparaitre pour donner l'accès soit aux modèles de prévision **M1** et **M2** ou au modèle de formulation **M3**.

En cliquant sur le bouton « **Compressive Strenght Prediction** », un menu d'un sous logiciel va s'afficher qui donne la main à l'utilisateur pour le choix du type de béton ensuite le type d'ajouts en utilisant une liste déroulante ainsi les conditions de la cure. Sachant que le sous logiciel pour cette version fonctionne seulement pour le béton ordinaire et pour les deux ajouts étudiés seulement (la pouzzolane naturelle et les cendres volantes).

La figure 4.17 montre le menu principal du sous logiciel proposé sous le nom de **(Concrete Compressive Strength Simulator V.1)**

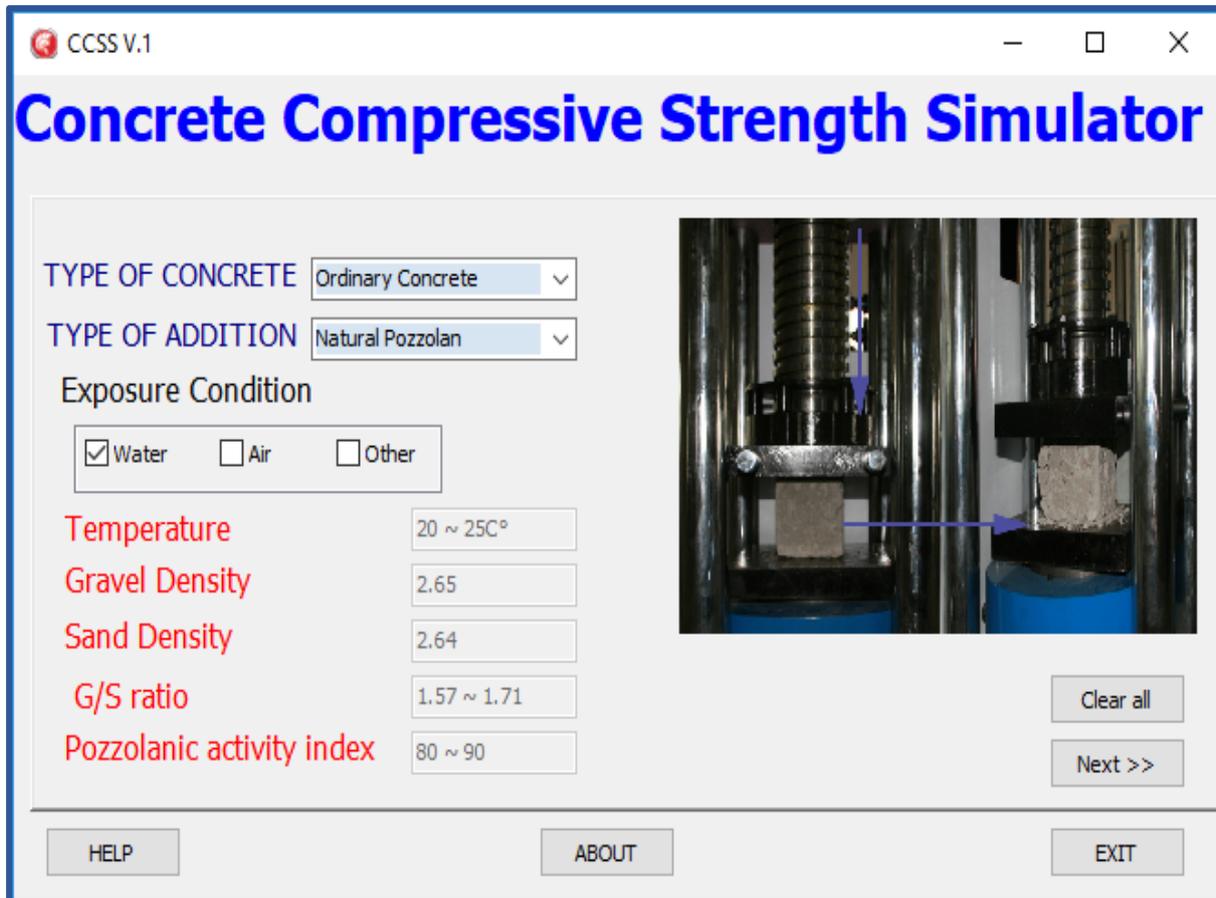


Figure 4.17 – Menu principal du logiciel de prévision de la résistance à la compression.

Par la suite en cliquant sur le bouton « **Next** », la page des proportions des mélanges s’affiche et l’utilisateur peut alors introduire les différentes données du mélange (Figure 4.18). Une fois que tous les paramètres ont été indiqués, l’utilisateur clique simplement sur le bouton « **Predict** », la résistance à la compression correspondante est obtenue, après l’exécution du modèle (**M1** ou **M2**) correspondant.

De même en cliquant sur le bouton « **Mix Design** », un menu d’un deuxième sous logiciel sera affiché qui donne la main à l’utilisateur pour le choix du type de béton ensuite le type d’ajouts et les conditions de cure (Figure 4.19). Le sous logiciel de cette version est valable seulement pour le béton ordinaire contenant des cendres volantes (**M3**).

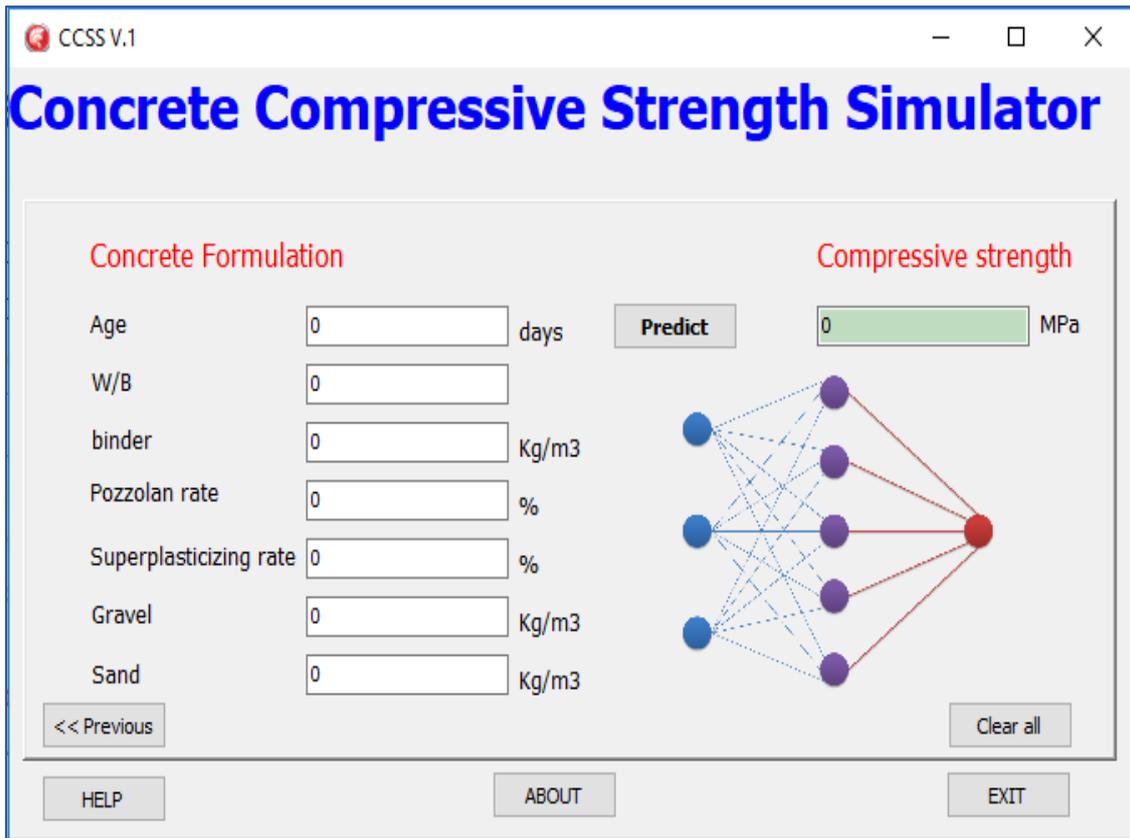


Figure 4.18 – Fenêtre de prévision de la résistance à la compression (Modèle M1).

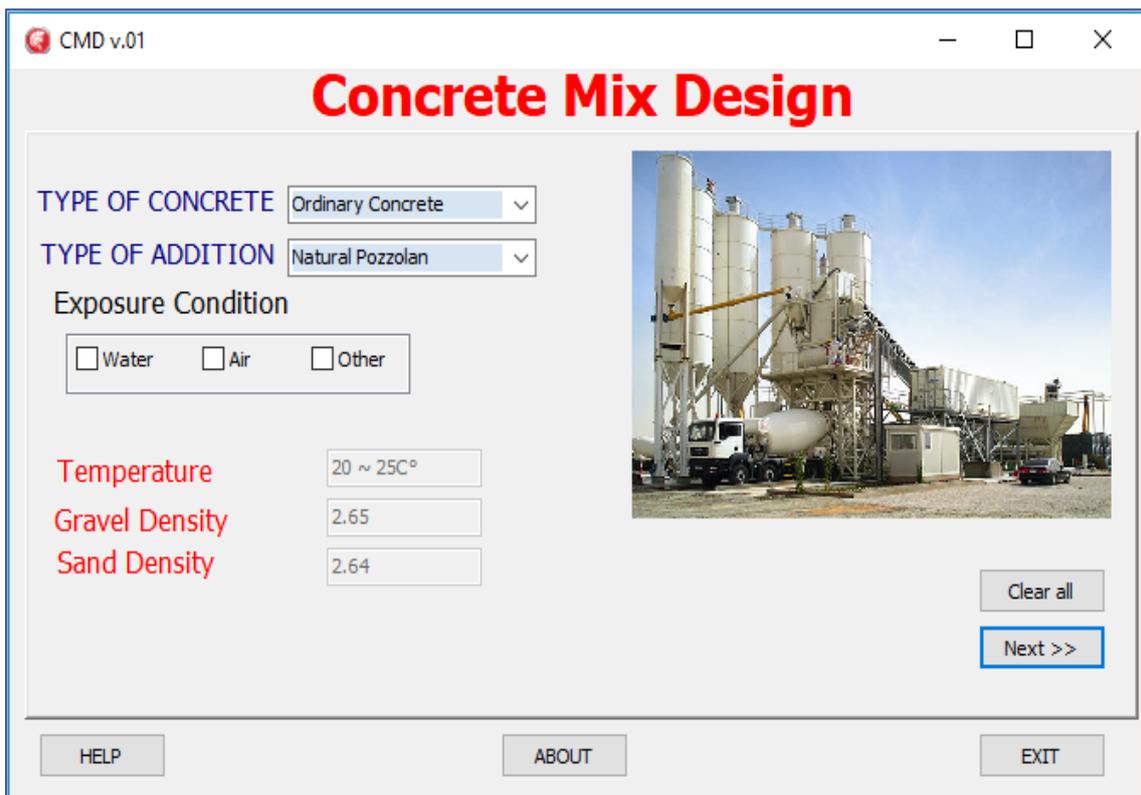


Figure 4.19 – Menu principal du logiciel de sous-logiciel de formulation « M3 »

Ensuite, en cliquant sur le bouton « **Next** », l'utilisateur peut formuler le béton selon les propriétés désirées (Figure 4.20).

Pour l'identification du type des cendres volantes représentée par l'indice **D**, l'utilisateur doit introduire la composition chimique considérée pour le calcul de l'indice **D**. la valeur de **D** sera calculée en appuyant sur le bouton « **Calculate D Index** »

Après l'identification de tous les paramètres d'inputs, on clique sur le bouton « **Calculate concrete mix** », la composition du béton sera affichée par la suite.

Figure 4.20 – Menu d'exécution du sous-logiciel de formulation « M3 »

4.9 Conclusion

Une nouvelle structure évoluée d'hybridation a été d'abord développée puis intégrée à un réseau de neurones avant son apprentissage pour optimiser son architecture en termes de poids de connexion et des biais qui sont souvent générés aléatoirement.

Trois modèles RNAG ont été développés pour la prévision de la résistance des bétons ordinaires contenant de la pouzzolane naturelle et les cendres volantes et pour la formulation des bétons ordinaires à base de cendres volantes. Les résultats obtenus par les trois modèles développés sont très satisfaisants.

Tous les modèles développés dans cette étude font l'objet de la conception d'un nouvel outil informatique dans la technologie de béton, où les modèles **M1**, **M2** et **M3** sont réunis dans une seule boîte de dialogue entre l'utilisateur et l'ordinateur sous forme d'un nouveau logiciel nommé « **Concrete Mix software** ».

#

CHAPITRE 05

*Validation expérimentale des modèles
développés.*

#

#

5.1 Introduction

L'objectif principal de ce chapitre est d'évaluer la capacité des modèles M1 et M2 développés pour prédire la résistance à la compression des bétons contenant la pouzzolane naturelle ou les cendres volantes, ainsi que la fiabilité du modèle M3 conçu pour la formulation du béton contenant des cendres volantes

Pour cet effet, un programme expérimental a été effectué. La première partie du programme a été réalisée au sein du **Laboratoire de Géomatériaux** à l'université de Chlef, sur des bétons à base de pouzzolane naturelle. La deuxième partie du programme expérimental effectuée sur des bétons à base de cendres volantes a été réalisée au sein du **Laboratoire des Matériaux Cimentaires Alternatifs** à l'université de Sherbrooke (CANADA).

5.2 Procédure et déroulement des essais

5.2.1 Matériaux utilisés

Pour la première partie du programme expérimental, le ciment utilisé est un ciment Portland CEMI 42.5 provenant de la cimenterie de SIG (Algérie). La pouzzolane utilisée, est une pouzzolane naturelle d'origine volcanique extraite du gisement de Bouhamdi situé au sud de Beni-Saf (Algérie), a été broyée à une finesse de 400 m²/kg. Les compositions chimique et physique du ciment et de la pouzzolane sont données dans le tableau 5.1. Le granulat fin utilisé, est un sable naturel de rivière ayant un module de finesse de 2.6 et les gros granulats sont des graviers de concassage de densité de 2.64. Un Superplastifiant de type naphthalène-sulfonates a été utilisé, sa densité relative à 25°C est de 1.21 avec un pourcentage en extrait sec de 40.5%. La teneur en super plastifiant a été calculée avec l'intention de maintenir une maniabilité suffisante pour remplir les moules et d'éviter tout effet de la variation de cette teneur sur les propriétés du béton.

Tableau 5.1 – Composition chimique du ciment et de la pouzzolane naturelle utilisés dans le première partie du programme expérimental.

Liant	SiO ₂	Al ₂ O ₃	Fe ₂ O ₃	CaO	MgO	SO ₃	SSB (m ² /kg)
Ciment	22.07	6.41	4.16	63.83	0.21	1.49	310
Pouzzolane Naturelle	46.86	16.62	9.37	9.38	2.84	0.36	400

La deuxième partie du programme expérimental a été réalisé pour mesurer l'ouvrabilité et la résistance à la compression à 3, 7, 28, 91 et 365 jours pour différents mélanges de bétons à base de cendres volantes.

Les matériaux utilisés dans cette étude expérimentale sont :

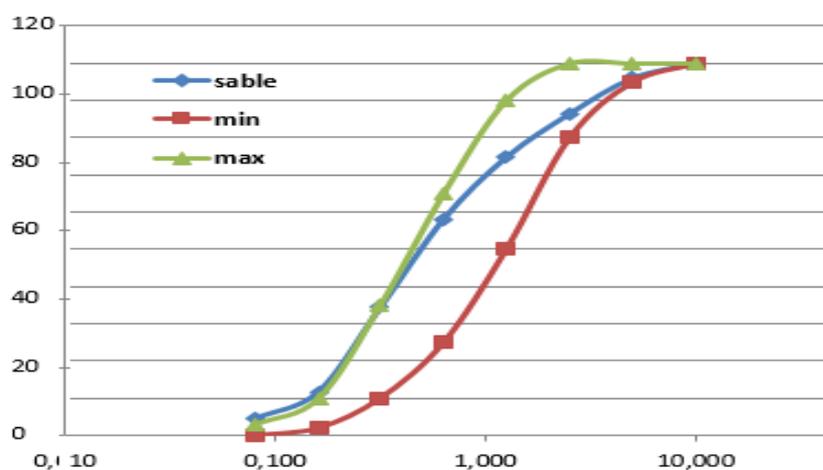
- Un ciment Portland de type GU commercialisé au Québec au CANADA.
- Des cendres volantes de type F (silico-alumineuses) selon la norme ASTM C 618-15 où la somme de $\text{SiO}_2 + \text{Al}_2\text{O}_3 + \text{Fe}_2\text{O}_3$ est supérieure à 70 %, et le taux de CaO est inférieur à 8%. La composition chimique et les caractéristiques physiques du ciment et des cendres volantes sont présentées dans le tableau 5.2
- L'eau utilisée est l'eau potable, exempte de toute impureté pouvant nuire à la qualité du béton. La température de l'eau de gâchage est de $20 \pm 2^\circ\text{C}$.
- Un superplastifiant (Eucon 37) a été utilisé comme adjuvant pour améliorer l'ouvrabilité des bétons avec faibles rapports E/L sa densité relative à 25°C est 1.21 avec un pourcentage en extrait sec de 40.5%.
- L'entraîneur d'Air utilisé est un liquide dérivé d'hydrocarbures soluble à l'eau, sa densité relative à 25°C est 1.0 avec un pourcentage en extrait sec de 5.0%;
- Le granulat fin utilisé dans le béton provient de la carrière St Dominique. Il s'agit d'un sable siliceux 0-5 mm. Ces propriétés physiques ainsi que sa courbe granulométrique sont présentées dans le tableau 5.3 et la figure 5.1 respectivement.
- Gros agrégats : 80% de granulats concassés de 5 à 14 mm et 20% de granulats concassés de 10 à 20 mm. les propriétés physiques ainsi que la courbe granulométrique selon les exigences granulométriques de la norme CSA.A23 sont présentées dans le tableau 5.3 et la figure 5.2 respectivement.

Tableau 5.2 – Composition chimique du ciment et des cendres volantes utilisées

Composants	Ciment	Cendres Volantes
SiO ₂	20.219	47.736
Al ₂ O ₃	4.330	23.861
Fe ₂ O ₃	2.471	16.971
CaO	61.55	4.652
MgO	1.997	1.011
Na ₂ O	0.144	0.838
K ₂ O	0.823	1.978
SO ₃	3.544	0.702
LOI	1.32	-
SiO ₂ + Al ₂ O ₃ + Fe ₂ O ₃	-	88.4
Propriété physique		
Densité relative	3.15	2.36
Surface spécifique Blaine m ² / kg	387	444

Tableau 5.3 – Caractéristiques physiques du sable naturel et des granulats utilisés

Caractéristique	Granulats fine (0-5 mm)	Gros granulats (5-10 mm)	Gros granulats (10-20 mm)
Densité brute	2.65	2.71	2.73
Absorption (%)	0.95	0.42	0.49

**Figure 5.1** – Courbes granulométriques du sable utilisé

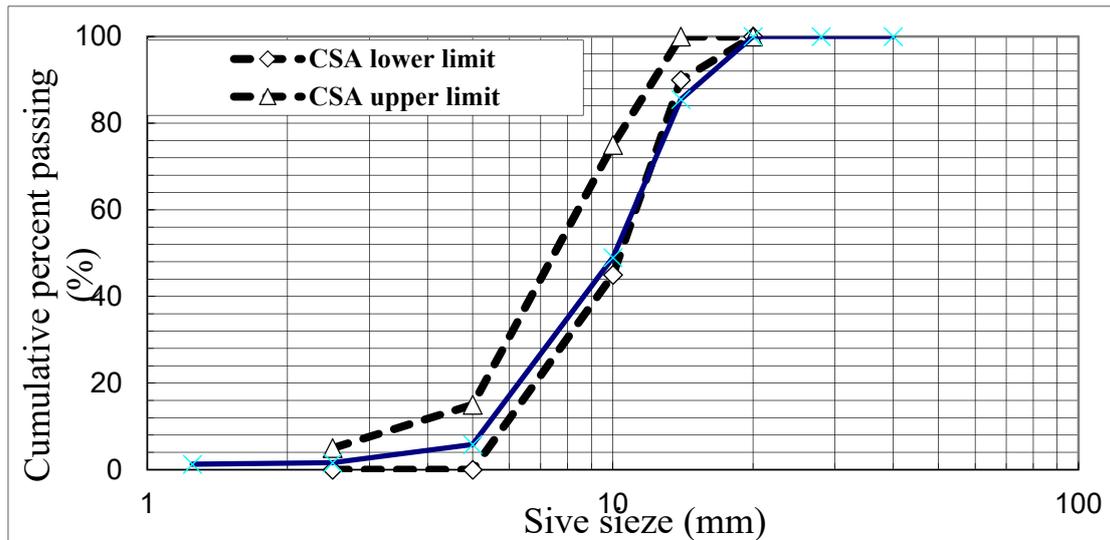


Figure 5.2 – Courbes granulométriques des granulats 5/14 utilisés.

5.2.2 Composition des bétons coulés

Douze (12) formulations ont été réalisées pour chaque ajout cimentaire. La composition des différents bétons étudiés à base de pouzzolane naturelle et de Cendre volante avec différents dosages et différents rapports E/L est résumée dans les tableaux 5.4 et 5.5 respectivement.

Tableau 5.4 – Formulations des bétons contenant de la PN.

Désignation	Rapport E/L	Ajouts (%)	ciment (kg/m ³)	Eau (L)	Adjuvants (%)	Gravier (kg/m ³)	Sable (kg/m ³)
B1P0	0.6	0	350	210	0	1130	720
B1P10		10	305	210	0	1130	720
B1P20		20	280	210	0	1130	720
B1P30		30	245	210	0	1130	720
B2P0	0.5	0	400	200	1	1100	720
B2P10		10	360	200	1.2	1100	720
B2P20		20	320	200	1.5	1100	720
B2P30		30	280	200	1.9	1100	720
B3P0	0.4	0	450	180	1.8	1050	720
B3P10		10	405	180	2.1	1050	720
B3P20		20	360	180	2.5	1050	720
B3P30		30	315	180	2.8	1050	720

Tableau 5.5 – Formulations des bétons contenant les CVs.

Désignation	E/L	Ciment (kg/m ³)	Ajout (kg/m ³)	Eau (kg/m ³)	Sable (kg/m ³)	Gros Agrégats (kg/m ³)		Adjuvants	
						80% 5-14 (mm)	20% 10-20 (mm)	SP (%)	EA (ml/m ³)
B1TM		380	0	228	519	856	214	0	327.2
B2CV20	0.6	304	76	228	498	856	214	0	433.2
B3CV30		266	114	288	487	856	214	0	500.1
B4CV50		190	190	288	465	856	214	0	583.3
B5TM		380	0	190	620	856	214	0	400.1
B6CV20	0.5	304	76	190	598	856	214	0	545.7
B7CV30		266	114	190	587	856	214	0	563.5
B8CV50		190	190	190	566	856	214	0	583.3
B9TM		380	0	152	721	856	214	0	433.2
B10CV20	0.4	304	76	152	698	856	214	0	500.0
B11CV30		266	114	152	687	856	214	0.9	583.3
B12V50		190	190	152	667	856	214	0.5	666.3

5.2.3 Procédures expérimentales

Pour la première partie du programme expérimental, juste après la confection, toutes les éprouvettes ont été couvertes afin d'éviter les risques d'évaporation excessive et le retrait plastique. Après 24 heures les éprouvettes ont été démoulées et conservées dans l'eau saturée de chaux à une température de $23 \pm 2^\circ\text{C}$.

Après un malaxage à sec de l'ordre d'une minute, l'eau de gâchage est ajoutée et le malaxage se poursuit pendant au moins deux minutes pour obtenir un mélange homogène. Juste après chaque malaxage, l'ouvrabilité a été mesurée en utilisant le cône d'Abrams.

Le serrage des éprouvettes a été effectué par une table vibrante. Les essais destructifs ont été exécutés, par l'écrasement des éprouvettes sous une charge appliquée jusqu'à la rupture, à l'âge de 2, 7, 28 et 90 jours. Chaque résultat d'essai correspond à la moyenne de trois éprouvettes.

Pour la deuxième partie du programme expérimental, les mélanges du béton ont été confectionnés dans un malaxeur à béton ayant une capacité de 110 litre. Des gâchées de 60 litres ont été confectionnées. Les mélanges ont été malaxés selon les séquences suivantes :

- ✓ Introduction du sable et malaxage pendant 1 minute.
- ✓ Détermination de la teneur en eau du sable.
- ✓ Ajout des gros granulats et de l'agent entraîneur d'air.
- ✓ mélanger dans la moitié de la quantité d'eau, malaxage pendant 3 minutes.
- ✓ Incorporation du ciment T = 0
- ✓ Malaxage 1 minute T = 1 min
- ✓ Ajout du superplastifiant homogénéisé dans le restant d'eau T = 1 min
- ✓ Malaxage 2 minutes T = 3 min
- ✓ Arrêt pendant 2 minutes T = 5 min
- ✓ Malaxage final 3 minutes. T = 8 min

Les mélanges de béton ont été effectués au laboratoire du béton et ciment de l'université de Sherbrooke. Pour les essais de la résistance à la compression, des éprouvettes cylindriques de dimension 100x200 mm ont été confectionnés et compactées à l'aide d'une tige en trois couches uniformes. Après 24 heures les éprouvettes ont été démoulées et conservées dans une salle humide de 100% d'humidité relative et à une température de $20 \pm 3^\circ\text{C}$ jusqu'au jour de l'essai.

5.3 Essais à l'état frais et durci

5.3.1 Mesure de l'ouvrabilité

L'ouvrabilité de chaque gâchée a été déterminée par l'essai d'affaissement au cône d'Abrams selon la norme ASTM C 143 (Figure 5.3).



Figure 5.3 – Mesure d'ouvrabilité avec le cône d'Abrams.

5.3.2 Masse Volumique et teneur en air

La masse volumique est la masse par unité de volume d'un béton. L'essai est effectué conformément à la norme CSA A23.2-4C Ou ASTM C231. L'appareillage utilisé est un Air-mètre (Figure 5.4). Le béton est placé en 3 couches consolidées avec 25 coups de pilon. La surface supérieure du béton est ensuite arasée à l'aide d'une règle. Ensuite, La détermination de la masse volumique du béton. A l'aide de l'Air-mètre on mesure le volume d'air occlus ou entraîné du béton.



Figure 5.4 – Mesure la teneur en Air et la masse volumique

5.3.3 Résistance à la compression

Les résistances à la compression ont été mesurées à 2, 7, 28 et 90 par l'essai à la presse hydraulique, selon la norme ASTM C 39. Chaque mesure de la résistance à la compression représente la valeur moyenne de trois valeurs.

5.4 Présentation et analyse des résultats

5.4.1 Etat frais

Les résultats des essais à l'état frais pour les bétons contenant des cendres volantes sont présentés dans le tableau 5.6.

Le tableau 5.6 montre que la masse volumique de tous les mélanges de béton varie entre 2200 et 2300 kg/m³, tandis que la teneur en air varie de 5.1 à 7.1%.

Tableau 5.6 – Propriétés du béton à l'état frais

Grandeurs mesurées	E/L	Cendres Volantes (%)			
		Témoin	20 CV	30 CV	50 CV
Air (%)	0.6	5.5	5.6	5.2	5.1
	0.5	6.0	7.0	7.4	7.6
	0.4	6.0	5.3	5.2	7.1
Affaissement (mm)	0.6	215	230	235	240
	0.5	110	170	175	210
	0.4	145	160	140	160
Masse volumique (kg/m ³)	0.6	2258	2237	2230	2223
	0.5	2286	2221	2194	2195
	0.4	2351	2333	2308	2232
Température (°C)	0.6	21.0	23.4	21.0	22.8
	0.5	21.8	22.6	22.0	23.0
	0.4	22.3	22.0	23.0	22.0

Les mélanges ont été confectionnés de telle manière à garder la même classe d'ouvrabilité, on prend la mesure juste après la fin du processus de malaxage, si on n'arrive pas à trouver l'ouvrabilité désirée on refait le malaxage du mélange pour une minute en ajoutant une quantité de superplastifiant utilisé (Eucon 37).

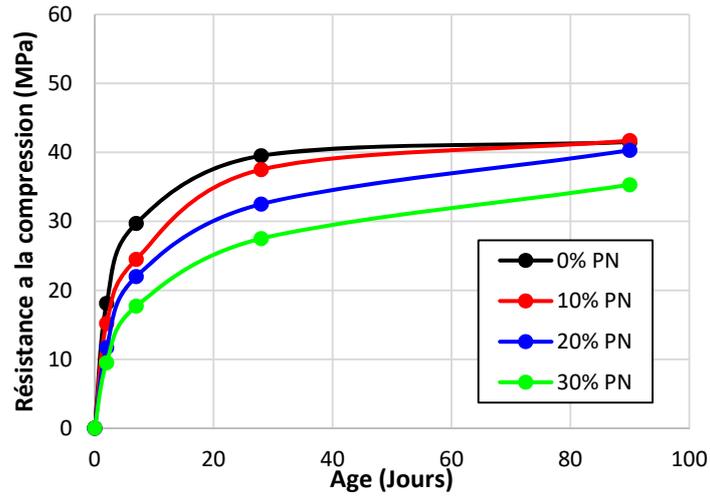
5.4.2 Etat durci

L'ensemble des résultats des essais réalisés sur la résistance à la compression des mélanges de béton contenant la pouzzolane naturelle sont indiqués dans le tableau 5.7 et reportés sur la figure 5.5. Chaque mesure de la résistance à la compression représente la moyenne de trois valeurs.

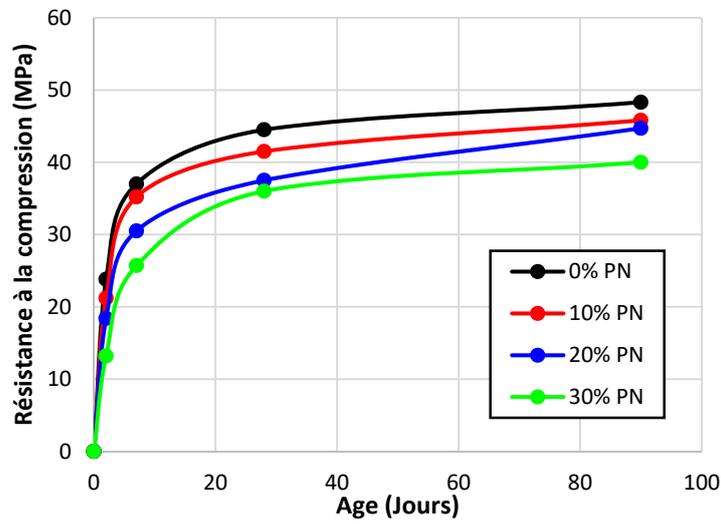
Tableau 5.7 – Résistance à la compression des Béton contenant de PN.

Désignation	E/L	PN (%)	Résistance à la compression par jour (MPa)			
			2	7	28	90
B1P0	0.6	0	18.1	29.7	39.5	41.5
B1P10		10	15.2	24.5	37.5	41.7
B1P20		20	11.7	22	32.5	40.3
B1P30		30	9.5	17.7	27.5	35.3
B2P0	0.5	0	23.8	37.0	44.5	48.3
B2P10		10	21.2	35.2	41.5	45.8
B2P20		20	18.4	30.5	37.5	44.7
B2P30		30	13.2	25.7	36.0	40.0
B3P0	0.4	0	26.3	43.8	54.0	57.0
B3P10		10	25.0	45.0	52.0	56.0
B3P20		20	20.0	35.8	51.0	53.8
B2P30		30	16.3	31.5	43.5	52.0

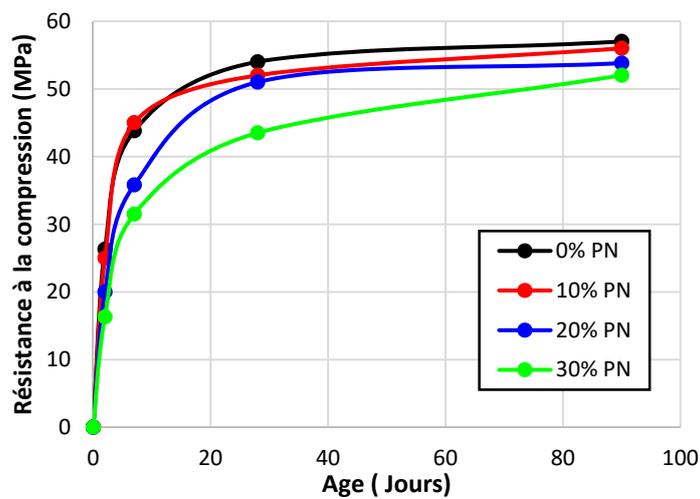
La figure 5.5 montre l'effet du taux de la pouzzolane naturelle et du rapport E/L sur la résistance à la compression. On constate que la résistance à la compression à un âge donné diminue avec l'augmentation du rapport E/L de 0.4 à 0.6. Elle diminue, aussi, lorsque le taux de remplacement de la pouzzolane naturelle augmente de 10 à 30%. Cependant, pour des taux de 10 et 20% de PN les résistances obtenues à long terme (90 jours) sont comparable à celles du béton témoin pour les trois rapports E/L



a) – E/L = 0.6



b) – E/L = 0.5



c) – E/L = 0.4

Figure 5.5 – Effet de taux de PN et le rapport E/L sur la résistance à la compression

Les résultats des essais réalisés sur la résistance à la compression des mélanges de béton contenant des Cendres Volantes sont indiqués dans le tableau 5.8 et reportés sur la figure 5.6.

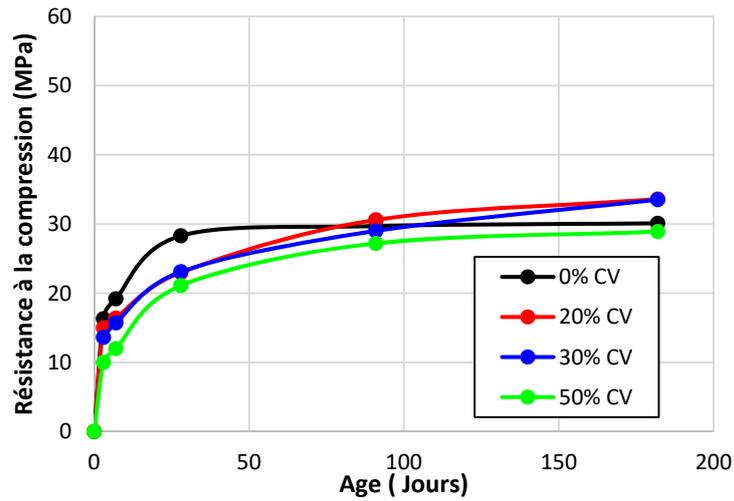
Tableau 5.8 – Résistance à la compression des Béton contenant de CV.

Désignation	E/L	CV(%)	Résistance à la compression par jour (MPa)				
			3	7	28	91	180
B1TM		0	16.3	19.2	28.3	27.7	30.1
B2CV20	0.6	20	15.0	16.4	23.0	30.6	33.6
B3CV30		30	13.6	15.7	23.1	29.0	33.5
B4CV50		50	10.0	12.0	21.1	27.2	28.9
B5TM		0	21.2	26.0	30.4	36.7	39.5
B6CV20	0.5	20	17.2	19.1	26.1	33.1	36.7
B7CV30		30	14.0	15.9	22.1	28.8	32
B8CV50		50	11.0	13.5	22.9	28.8	30.5
B9TM		0	32.5	34.7	41.1	49.6	50.7
B10CV20	0.4	10	30.1	35.0	41.5	51.0	55.9
B11CV30		30	24.6	28.6	39.4	44.1	50.3
B12CV50		50	15.5	19.3	28.8	33.4	38.4

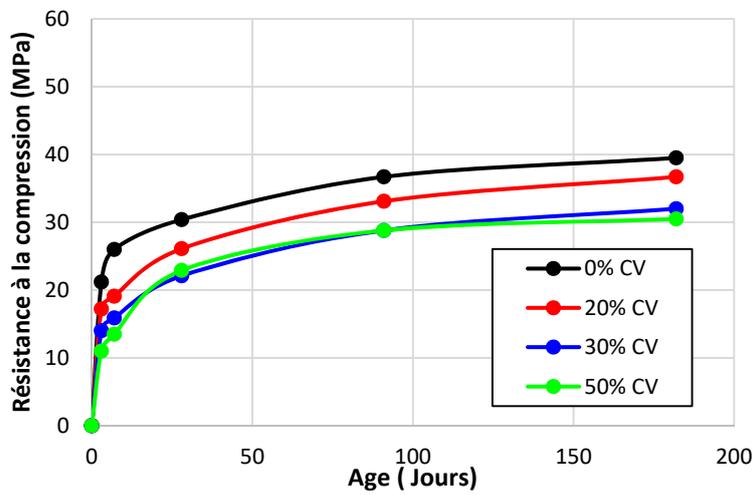
De même la figure 5.6 montre l'effet du taux des cendres volantes et du rapport E/L sur la résistance à la compression. D'après cette figure, la résistance à la compression est inversement proportionnelle au rapport E/L.

D'autre part, la résistance à la compression des bétons contenant différents dosages de cendres volantes sont comparables à celle du béton témoin au-delà de 180 jours de cure. A l'exception de 50% de substitution de CV, des diminutions de la résistance à la compression de 3.9, 23.9 et 24.5% par rapport au béton témoin ont été observées pour les rapports E/L de 0.6, 0.5 et 0.4 respectivement. Par contre, pour un taux de 20% de CVs, une augmentation de 11.62 et 10,25% de la résistance par rapport au béton témoin a été observée pour E/L de 0.6 et 0.4 respectivement.

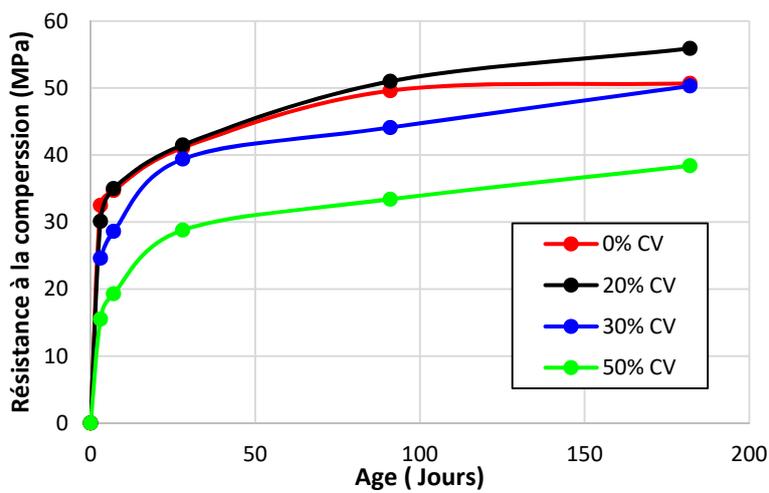
On observe que l'introduction de la pouzzolane naturelle et des cendres volantes ne produit pas une amélioration immédiate de la résistance, la perte de résistance aux jeunes âges est proportionnelle aux taux de substitution du ciment à cause de l'effet de dilution de l'ajout et à la lenteur de la réaction pouzzolanique.



a) – E/L = 0.6



b) – E/L = 0.5



c) – E/L = 0.4

Figure 5.6 – Effet de taux de CV et le rapport E/L sur la résistance à la compression

5.5 Validation des modèles de prévision de la résistance (M1 et M2)

Pour la prévision de la variation de la résistance à la compression avec le temps, plusieurs modèles ont été proposés par différents codes et règlements. Les modèles donnés par les équations 5.1 et 5.2 ont été recommandés par Le Comité ACI 209 et le CEB-FIP respectivement

$$(f'_c)_t = \left(\frac{t}{\alpha + \beta t} \right) (f'_c)_{28} \quad (5.1)$$

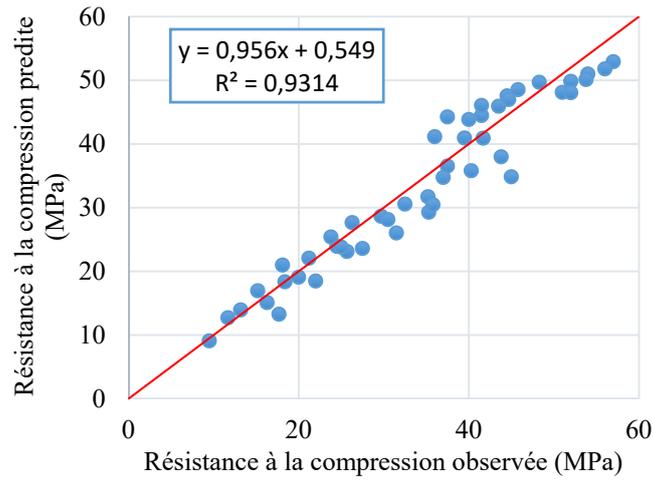
$$(f'_c)_t = \exp \left\{ s \cdot \left[1 - \left(\frac{28}{t/t_1} \right)^{0.5} \right] \right\} \cdot (f'_c)_{28} \quad (5.2)$$

Où :

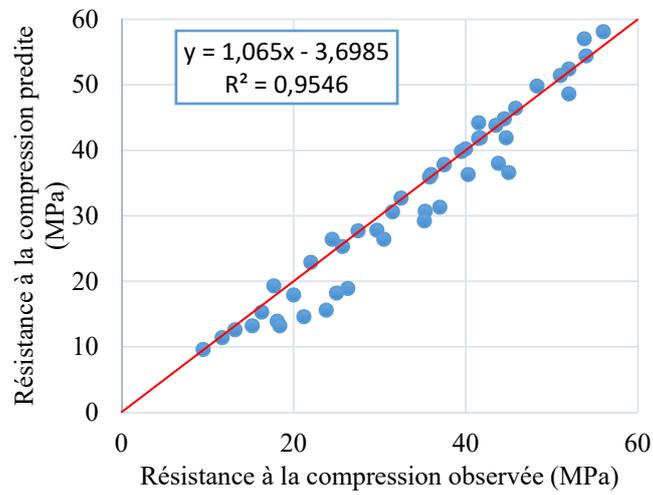
- $(f'_c)_t$ est la résistance à la compression du béton à l'âge t en MPa,
- « t » est le temps en jours,
- $(f'_c)_{28}$ est la résistance à la compression à 28 jours en MPa.
- « α » et « β » sont des constants dépendent de type du ciment utilisé et les conditions de cure (pour le CEMI, $\alpha = 4$ et pour une cure à l'eau, $\beta = 0.85$).
- « s » dépend de la classe du ciment ($s = 0.25$ Pour une classe de ciment de 32.5 et 42.5 R)

Les comparaisons entre les résultats expérimentaux et les résultats obtenus par les modèles M1 et M2 ainsi que les modèles proposés par l'ACI et le CEB sont présentées dans les figure 5.7 et 5.8 respectivement.

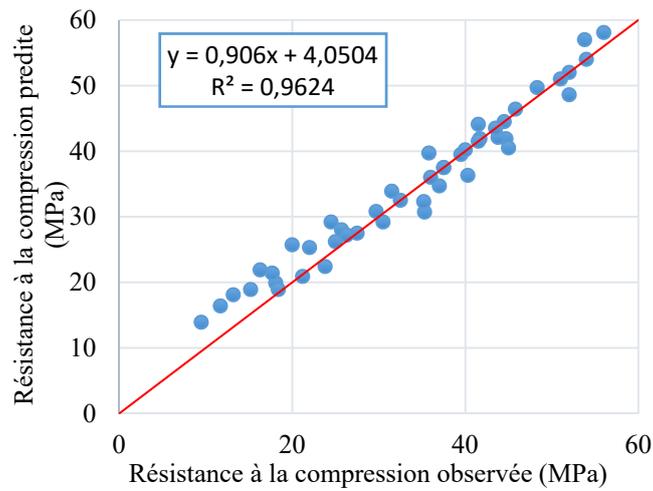
Les figures 5.7 et 5.8 montrent une bonne concordance entre les résultats prédits par les modèles M1 et M2 et les résultats expérimentaux avec des coefficients de détermination de 0.93 et 0.94 respectivement. Ces résultats sont comparables avec les résultats obtenus par les formules proposées par l'ACI et le CEB.



a) M1



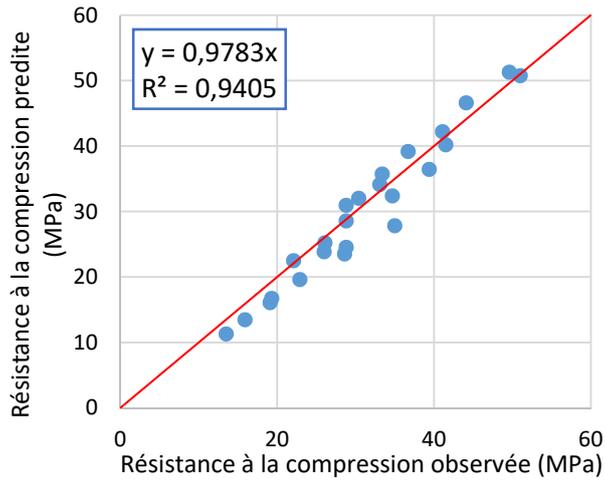
b) ACI



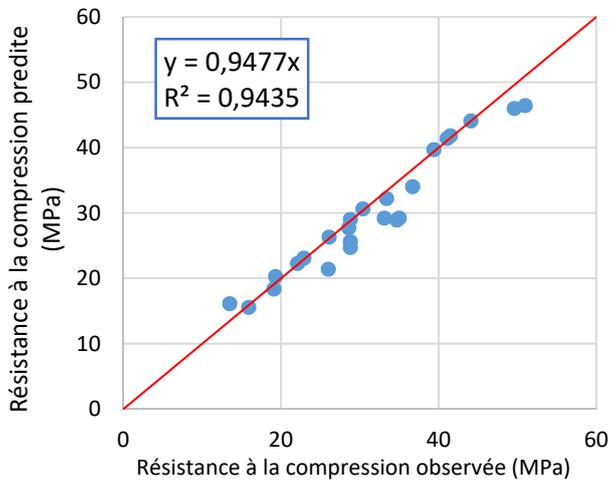
c) CEB

Figure 5.7 – Comparaison de la résistance à la compression observée et prédite par les modèles :

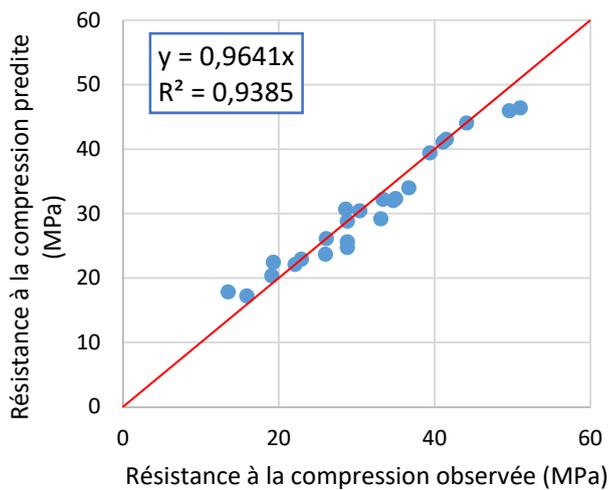
(a) M1. (b) ACI. et (c) CEB



a) M2



b) ACI



c) CEB

Figure 5.8 – Comparaison de la résistance à la compression observée et prédite par les modèles :

(a) M2. (b) ACI. et (c) CEB

La comparaison a été faite en terme de différents indicateurs de performance (ou d'erreur) notamment : RMSE (Root Mean Square Error) (Eq. 4.3), le coefficient de détermination R^2 (Eq. 4.5) et l'erreur absolues moyenne (Eq. 5.3) sont présentés dans le tableau 5.9

$$E(\%) = \left| \frac{t_j - o_j}{o_j} \right| \times 100 \quad (5.3)$$

Où :

t_j est la valeur cible de « j^{th} » échantillon, « O_j » est la valeur de sortie de « j^{th} » échantillon, et « p » est le nombre de l'échantillon.

Tableau 5.9 – Comparaison entre les modèles M1 et M2 développées et le les formules proposé par ACI et CEB

Modèle	RMSE	E(%)	R^2
M1	3.50	8.65	0.9314
ACI	3.42	8.17	0.9546
CEB	2.72	8.76	0.9624
M2	2.77	8.40	0.9405
ACI	2.76	6.44	0.9435
CEB	2.43	6.64	0.9385

D'après le tableau 5.9, les modèles M1 et M2 ont des performances, **RMSE** et **E** faibles et un coefficient de détermination R^2 très élevé comparables aux modèles proposés par l'ACI et le CEB.

5.6 Validation du modèle de formulation de béton (M3)

Pour ce modèle la comparaison a été faite en termes d'erreur absolues moyenne (E%), le vecteur d'input introduit au modèle de formulation M3 est présenté dans le tableau 5.10. les données sont obtenues à partir du deuxième programme expérimentale.

Tableau 5.10 – Combinaison d'entrées introduite au modèle

Input					
Résistance à la compression (MPa)	Ouvrabilité (mm)	Ajout %	Indice D	G/Gr	Nombre de jours
26,0	110	0	19	0,63	7
19,1	170	20	19	0,64	7
15,9	175	30	19	0,65	7
13,5	210	50	19	0,65	7
34,7	145	0	19	0,60	7
35,0	160	20	19	0,61	7
28,6	140	30	19	0,61	7
19,3	160	50	19	0,62	7
30,4	110	0	19	0,63	28
26,1	170	20	19	0,64	28
22,1	175	30	19	0,65	28
22,9	210	50	19	0,65	28
41,1	145	0	19	0,60	28
41,5	160	20	19	0,61	28
39,4	140	30	19	0,61	28
28,8	160	50	19	0,62	28

Les valeurs d'erreur absolue moyenne (E %) obtenus sont représenté dans le tableau 5.11

Tableau 5.11– Erreur absolues moyenne

Output	Erreur moyenne E %
Liant	2.2
E/L	4.1
Granulats	6.2

D'après le tableau 5.11, on constate que la valeur d'erreur est très petite, ce qui montre la performance du modèle M3 pour prédire la composition des bétons contenant les cendres volantes.

5.7 Conclusion

Le programme expérimental réalisé dans le but d'obtenir des résultats expérimentaux sur les propriétés à l'état frais et à l'état durci des bétons contenant de la pouzzolane naturelle et les cendres volantes. vingt-quatre (24) mélanges de bétons avec différents rapports eau-liant ont été réalisés et testés et des résultats sur l'ouvrabilité et la résistance à la compression ont été obtenus. Ces derniers ont été utilisés pour valider les modèles **M1**, **M2** et **M3** développés dans le chapitre 4.

La confrontation des résultats prédits par les modèles RNAG (**M1**, **M2** et **M3**) aux résultats expérimentaux obtenus dans cette étude, confirme la fiabilité des modèles développés. De plus, les modèles **M1** et **M2** présentent des performances comparables à celles des modèles recommandés par le ACI-209 et le CEB-FIP, ce qui montre la pertinence de ses modèles pour prévoir efficacement la résistance à la compression des bétons aux ajouts cimentaires.

#

CHAPITRE 06

Performances des modèles développés.

#

#

6.1 Introduction

La performance des réseaux de neurones se mesure par la manière dont ils savent prévoir des données inconnues (un ensemble de données inconnues est un ensemble de données n'ayant pas été utilisé lors de la phase d'apprentissage). Ce processus s'appelle la généralisation.

La question de la généralisation est en fait une question majeure qui se pose lors de l'apprentissage des réseaux de neurones, le véritable problème consiste à réussir à construire un réseau capable également de bien prévoir les nouvelles données. Par conséquent, lors de l'apprentissage des réseaux de neurones, nous devons toujours tenir compte des questions de performance et de généralisation.

6.2 Généralisation des modèles RN développés

La représentation des modèles de prévision (**M1**, **M2**) et de formulation (**M3**) de béton peut être faite par l'étude de l'influence de la variation des paramètres d'entrées choisis sur la sortie désirée. Le tableau 6.1 montre les limites de variation des paramètres pour le fonctionnement correct des modèles développés conçus pour formuler des bétons ordinaires aux pouzzolanes et aux cendres volantes. Les valeurs maximum et minimum sont tirées de la base de données utilisée pour l'élaboration des modèles (voir Chapitre 3).

Une étude de sensibilité des modèles développés a été faite où les modèles de prévision de la résistance à la compression sont testés par des données que nous avons proposées (Tableaux de 6.2 à 6.4). Les données sont organisées de telle façon, qu'on a varié chaque fois un paramètre d'entrée, pour vérifier les relations connues dans la technologie de béton entre les propriétés et la composition de mélange du béton, comme l'effet de l'âge sur la résistance, l'effet de rapport E/C ...etc.

Tableau 6.1 – Valeurs limites du fonctionnement des Modèles développés

Modèles	Paramètres	Min	Max
M1	Liant (kg/m ³)	350	500
	Eau/ liant	0.4	0.6
	Taux de la pouzzolane (%)	0	50
	Superplastifiant (%)	0	2.5
	Gravier (kg/m ³)	900	1200
	Sable (kg/m ³)	600	800
	Age (Jour)	1	270
	Résistance à la compression (MPa)	5	50
M2	Liant (kg/m ³)	300	450
	Eau/ liant	0.4	0.6
	Taux de Cendre volante (%)	0	50
	Indice D	1	50
	Gravier (kg/m ³)	900	1150
	Sable (kg/m ³)	500	800
	Age (Jour)	3	200
	Résistance à la compression (MPa)	5	50
M3	Résistance à la compression (MPa)	5	45
	Ouvrabilité (mm)	8	20
	Taux de Cendre volante (%)	0	50
	Indice D	1	50
	Rapport Gravier /Granulats	0.6	0.7
	Age (Jour)	1	180
	Liant (kg/m ³)	250	550
	Eau/ liant	0.4	0.6
Granulats (kg/m ³)	1500	2000	

Tableau 6.2 – Vecteur données pour l'étude paramétrique du modèle M1

E/L	Age (Jour)	Liant (kg/m³)	PN (%)	SP (%)	Gravier (kg/m³)	Sable (kg/m³)
0.6	2	350	de 0 à 50	0	1200	700
	7	350				
	28	350				
	90	350				
0.5	2	400	de 0 à 50	1	1200	700
	7	400				
	28	400				
	90	400				
0.4	2	450	de 0 à 50	2	1200	700
	7	450				
	28	450				
	90	450				

Tableau 6.3 – Vecteur données pour l'étude paramétrique du modèle M2

E/L	Age (Jour)	Liant (kg/m³)	CV (%)	Indice D (%)	Gravier (kg/m³)	Sable (kg/m³)
0.6	2	300	de 0 à 50	0	1050	700
	7	300				
	28	300				
	90	300				
0.5	2	350	de 0 à 50	5	1050	700
	7	350				
	28	350				
	90	350				
0.4	2	400	de 0 à 50	30	1050	700
	7	400				
	28	400				
	90	400				

Tableau 6.4 – Vecteur données pour l'étude paramétrique du modèle M3

Résistance à la compression (MPa)	Ouvrabilité (mm)	Age (Jour)	CV (%)	Indice D (%)	Gravier /Granulat
de 20 à 50	de 5 à 20	2	de 0 à 50	0	de 0.55 à 0.65
		7			
		28			
		90			
de 20 à 50	de 5 à 20	2	de 0 à 50	5	de 0.55 à 0.65
		7			
		28			
		90			
de 20 à 50	de 5 à 20	2	de 0 à 50	30	de 0.55 à 0.65
		7			
		28			
		90			

6.3 Résultats et discussions

6.3.1 Modèle de prévision de la résistance à la compression M1

Les variations des paramètres d'entrée du modèle sont représentées dans le tableau 6.2, deux effets importants ont été pris en considération, les résultats sont illustrés dans la figure 6.1.

6.3.1.1 Effet du rapport E/C

La résistance d'un béton bien compacté apparaît comme étant inversement proportionnelle au rapport "eau/ciment". Cette relation, présentée comme une loi, est en fait une véritable règle, établie par Duff Abrams en 1919 (voir [Neville, 1995](#)).

La figure 6.1 montre la variation de la résistance à la compression obtenue par le modèle en fonction du rapport E/L pour un facteur d'âge de 2, 7, 28, et 90 jours

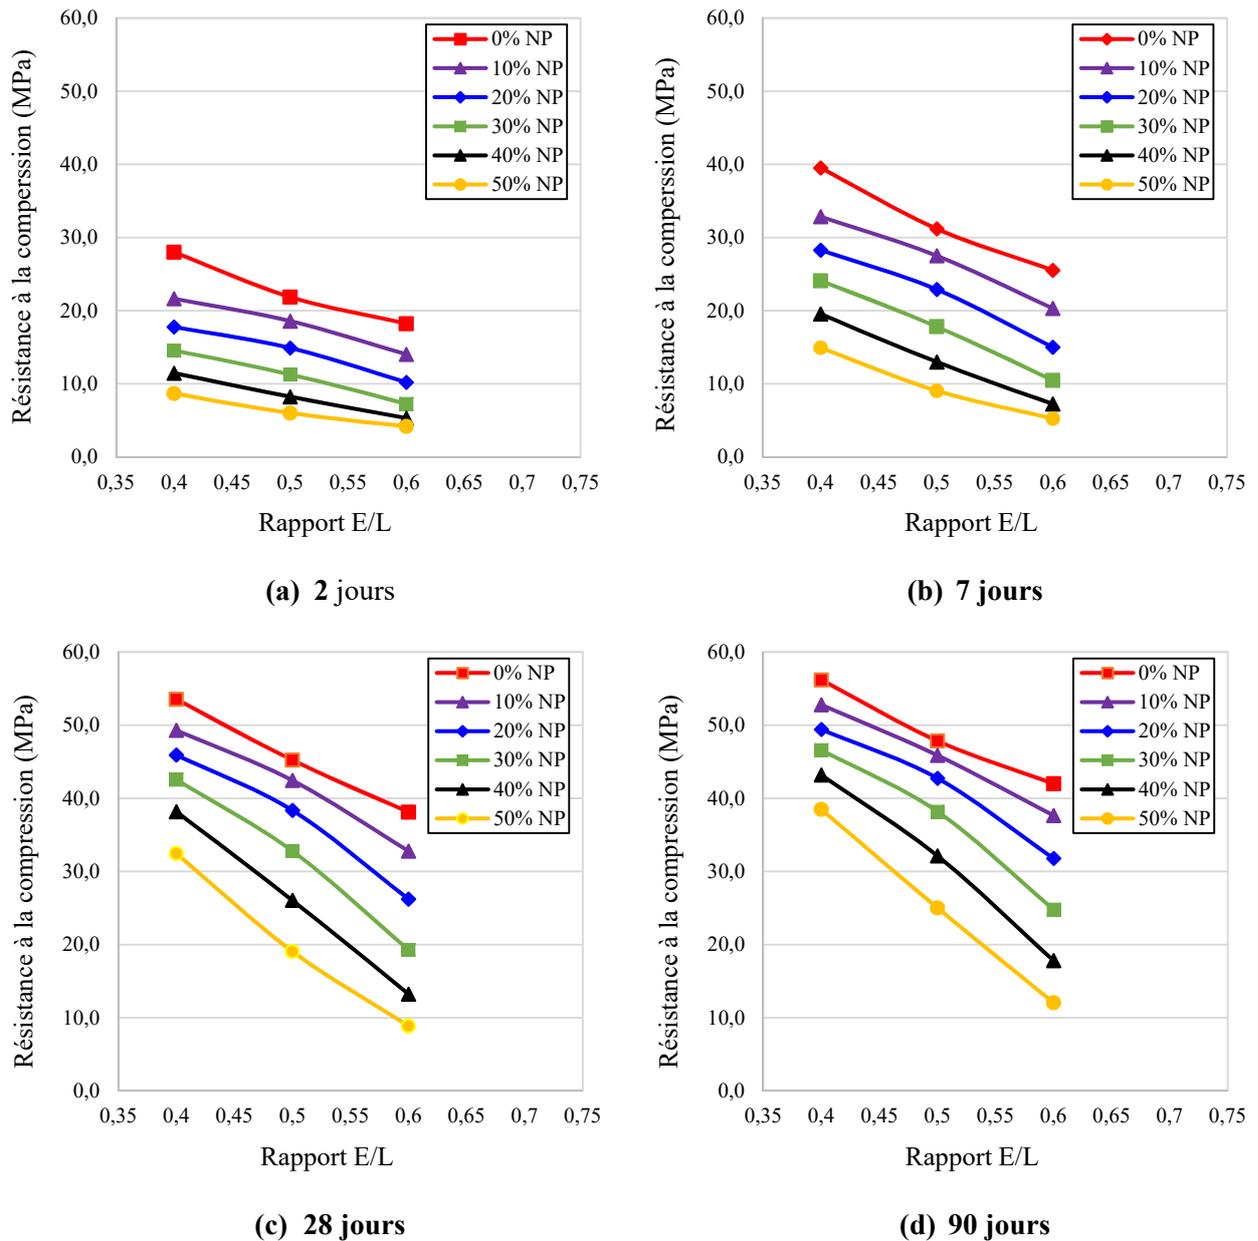


Figure 6.1 – Effet du rapport E/L sur la résistance à la compression.

D'après cette figure, la résistance à la compression augmente avec la diminution du rapport E/L pour différents taux de substitutions de PN (0, 10, 20, 30, 40, 50 %) et à tous les âges (de 2 jours jusqu'à 90 jours).

Les résultats obtenus sont en bonne concordance avec les résultats publiés par plusieurs chercheurs. De même, ces résultats révèlent fidèlement la relation entre la résistance à la compression et le rapport E/L très connue dans la technologie de béton.

D'autre part, l'analyse des résultats obtenus montre que pour un rapport $E/L = 0.4$ et avec l'utilisation de 2% de superplastifiant et un taux de remplacement de 40% de pouzzolane naturelle on trouve la même résistance à la compression d'un béton de $E/L = 0.6$ et 0% de pouzzolane, ce qui représente un gain économique et environnementale.

6.3.1.2 Effet de l'âge et du taux de pouzzolane sur la résistance à la compression

La figure 6.2 montre la variation de la résistance à la compression en fonction de l'âge pour les différents taux de substitution de pouzzolane naturelle (de 0 à 50%) et des rapports E/L variant de 0,4 à 0,6.

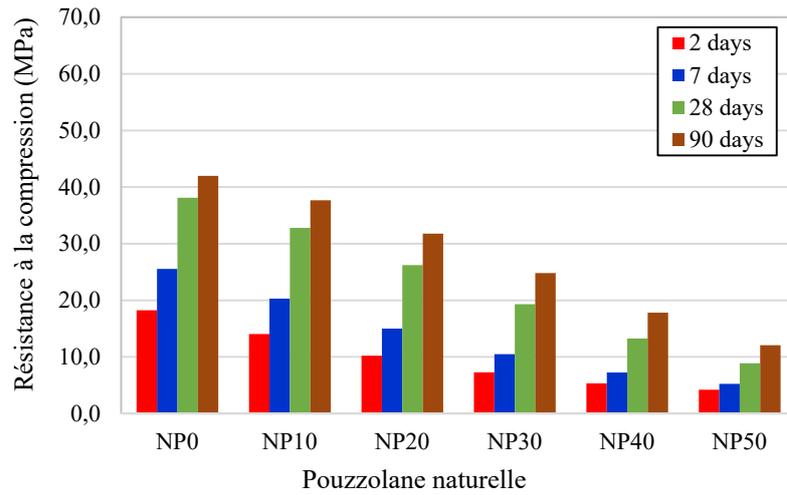
Cette figure montre l'augmentation de la résistance à la compression en fonction de l'âge et sa diminution avec l'augmentation du taux de substitutions de la pouzzolane naturelle.

On observe aussi que la résistance à la compression augmente avec une cinétique rapide de 2 à 28 jours par rapport à la période de 28 à 90 jours. Ceci est affirmé dans la technologie de béton : la cinétique du développement de la résistance à la compression du béton diminue considérablement à partir de 28 jours.

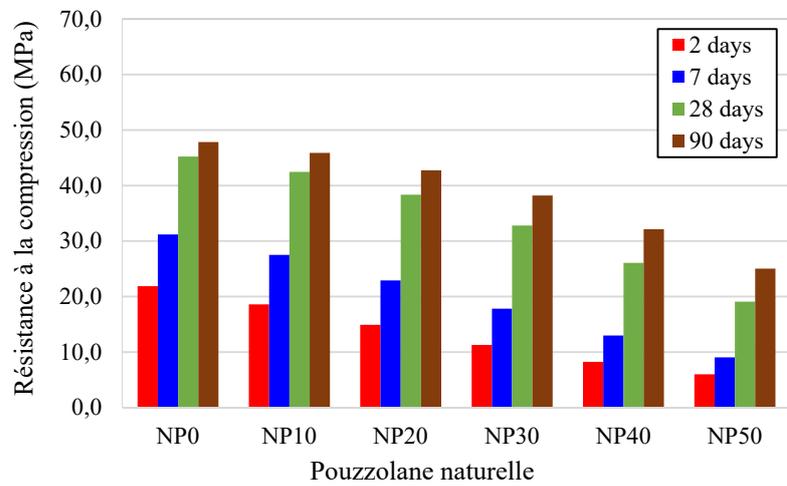
On observe aussi que l'introduction de la pouzzolane naturelle ne produit pas une amélioration immédiate de la résistance à l'opposé du mélange témoin. La perte de résistance aux jeunes âges, qui a été proportionnelle aux taux de substitution du ciment, est due à l'effet de dilution de l'ajout et aussi bien à la lenteur de la réaction pouzzolanique.

La figure 6.2 montre que le gain de la résistance à la compression de 28 à 90 jours pour un taux de 40 ou 50% de pouzzolane est très grand par rapport à celui du béton témoin (avec 0% de pouzzolane naturelle), cela est dû au déclenchement de la réaction pouzzolanique à long terme.

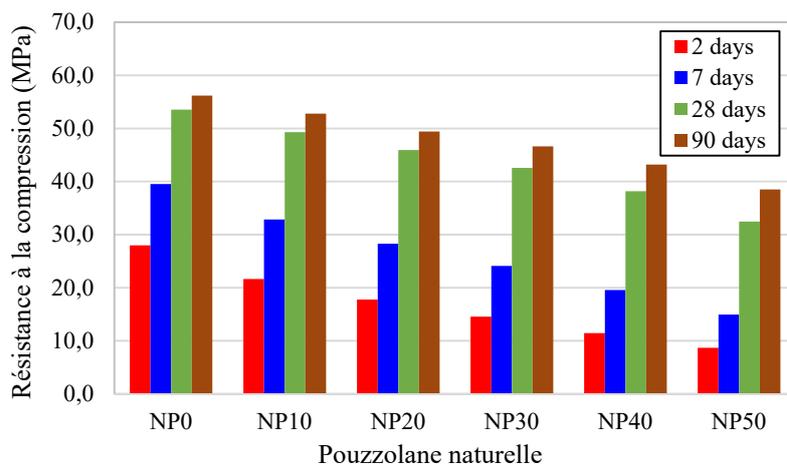
Il est clairement montré que la diminution du rapport E/L avec l'utilisation de superplastifiant a introduit une augmentation considérable de la résistance à la compression même avec des taux élevés de pouzzolane naturelle. A 28 jours, pour un taux de 40% de PN, un gain de résistance de 13 et 38 MPa a été présenté pour des rapports E/L de 0.6 à 0.4 respectivement.



a) E/L=0.6



b) E/L=0.5



c) E/L=0.4

Figure 6.2 – Effet de l’âge sur la résistance à la compression des bétons à base de PN.

6.3.2 Modèle de prévision de la résistance à la compression M2

Les variations des paramètres d'entrées du modèle sont représentées dans le tableau 6.3, deux effets importants ont été pris en considération, les résultats sont représentés dans la figure 6.3.

6.3.2.1 Effet du rapport E/C

La figure 6.3 montre la variation de la résistance à la compression obtenue par le modèle **M2** en fonction du rapport E/L à l'âge de 28 jours.

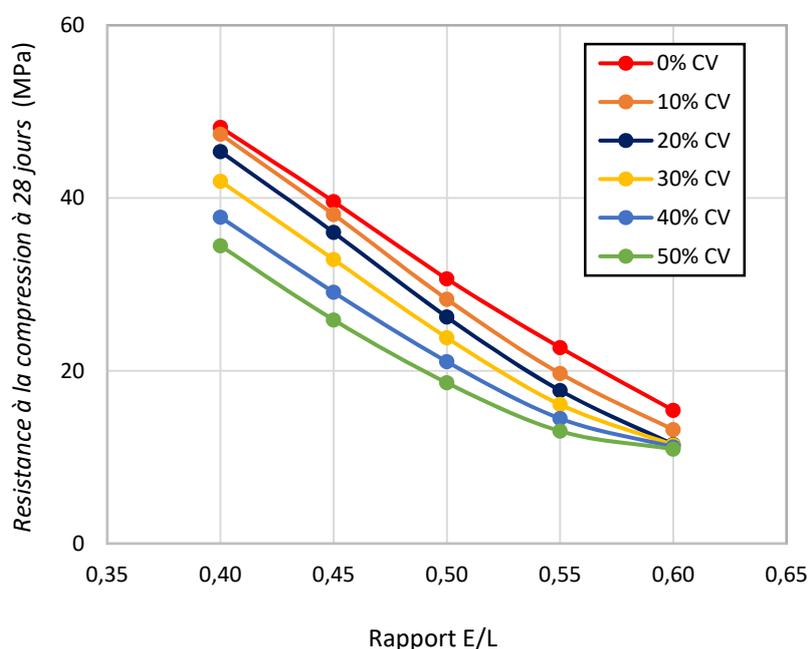


Figure 6.3 – Effet du rapport E/L sur la résistance à la compression a 28 jours

Il est bien clair que la résistance à la compression est inversement proportionnelle au rapport E/L : lorsqu'on augmente la valeur du rapport E/L de 0.4 à 0.6, la résistance à la compression diminue considérablement, cela est valable pour différents dosages de cendres volantes.

6.3.2.2 Effet de Cendres volantes

La figure 6.4 montre la variation de la résistance à la compression obtenue par le modèle **M2** en fonction de l'âge et du taux de substitution des cendres volantes.

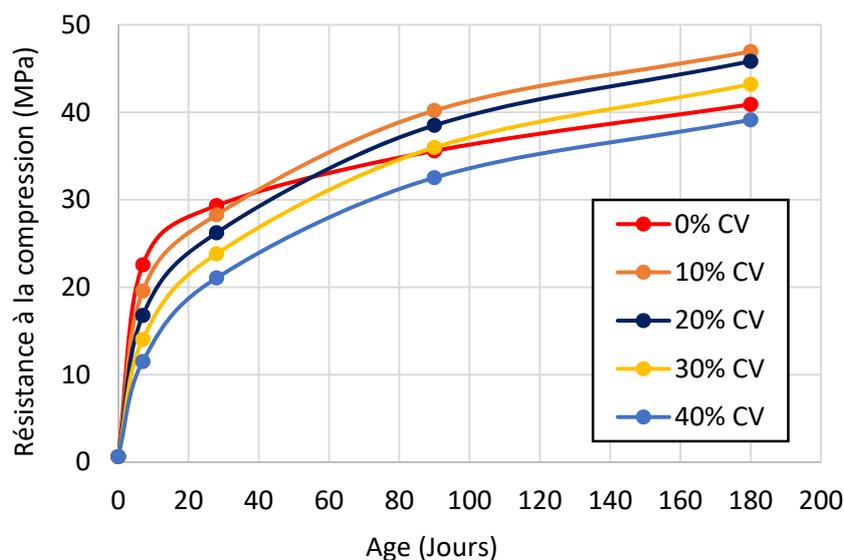


Figure 6.4 – Effet de l'âge sur la résistance à la compression des bétons à base de CV.

Les caractéristiques des cendres volantes (composition chimique, granulométrie, réactivité, ...), le ciment utilisé, les proportions de chaque type de béton, la température et autres conditions de durcissement, ainsi que la présence d'autres additifs, affectent à la fois la résistance à la compression à un âge donné et le gain de résistance du béton aux cendres volantes (Hobbs, 1983 ; Berry and Malhotra, 1986; ACI Comite 232, 2003)

Bien que les mélanges de béton contenant des cendres volantes possèdent une tendance d'augmenter la résistance avec une vitesse plus lente que le béton sans cendres volantes, au jeune âge. Cependant, la résistance à la compression à long terme est habituellement plus élevée (Bremner and Thomas, 2004) due à l'activité pouzzolanique des cendres volantes.

En raison de leur finesse élevée et de leur activité pouzzolanique, les cendres volantes dans le béton améliorent la qualité de la pâte de ciment et la microstructure de la zone de transition entre la matrice cimentaire et les agrégats. Le processus continu de raffinement des pores et l'inclusion des produits d'hydratation des cendres volantes dans le béton, justifient le gain de développement de résistance avec le durcissement du béton (Joshi and Lohtia, 1997).

Les résultats obtenus par le modèle **M2** proposé dans cette étude, qui sont présentés dans la figure 6.4 sont en concordance avec les résultats trouvés dans la littérature. La figure 6.4 montre que les cendres volantes contribuent au développement de la résistance à la

compression après 28 jours. On remarque aussi que la résistance d'un béton contenant 10% de CV dépasse celle du béton témoin (0% de CV) à partir de 40 jours.

D'autre part, le développement du gain de résistance nécessite plus de temps lorsque le taux de substitution des cendres volantes augmente, la figure 6.4 montre que pour 10, 20 et 30% de cendres volantes, on a obtenu un gain de résistance de 6% au-delà de 50, 70 et 100 jours respectivement. Les mêmes résultats ont été trouvés par Thomas (2007) comme illustré dans la Figure 6.5.

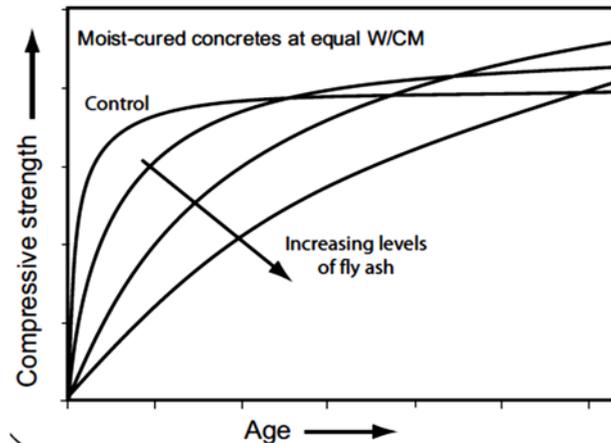


Figure 6.5 – L'effet de cendre volante sur le développement de La résistance à la compression (Thomas 2007)

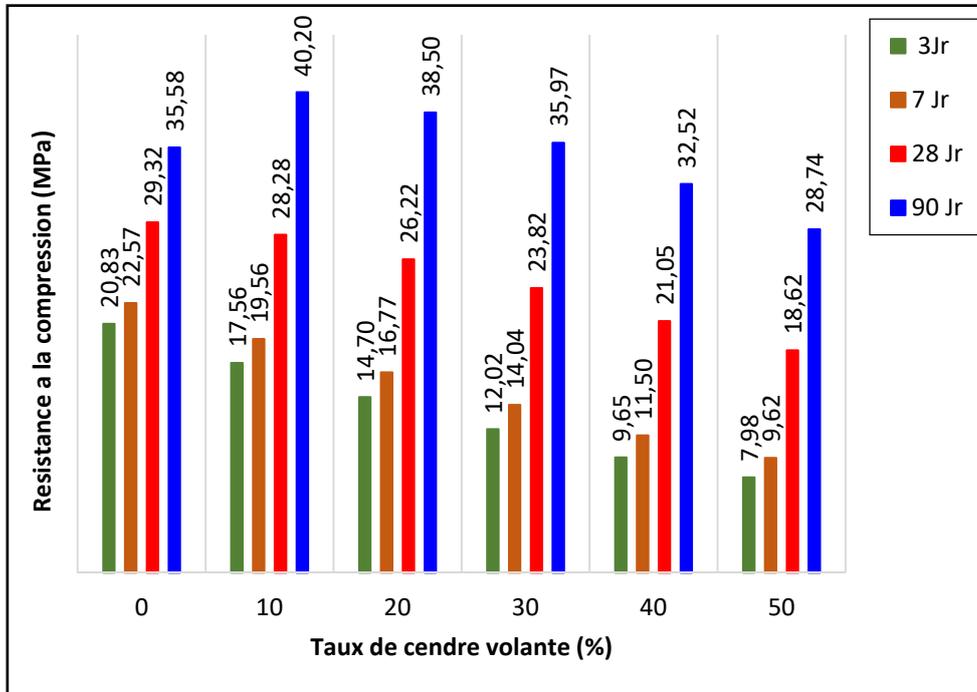
➤ *Effet de la classe des cendres volantes*

Les bétons aux cendres volantes à haute teneur de calcium (classe C) montrent un gain de résistance plus rapide au jeune âge que le béton fabriqué avec des cendres volantes à faible teneur de calcium (classe F) car les cendres de classe C présentent souvent un taux de réaction pouzzolanique plus élevé aux jeunes âges que les cendres de classe F. Par contre, à long terme, les CV de classe F donnent un gain de résistance plus élevé que la classe C (Donald, 2006).

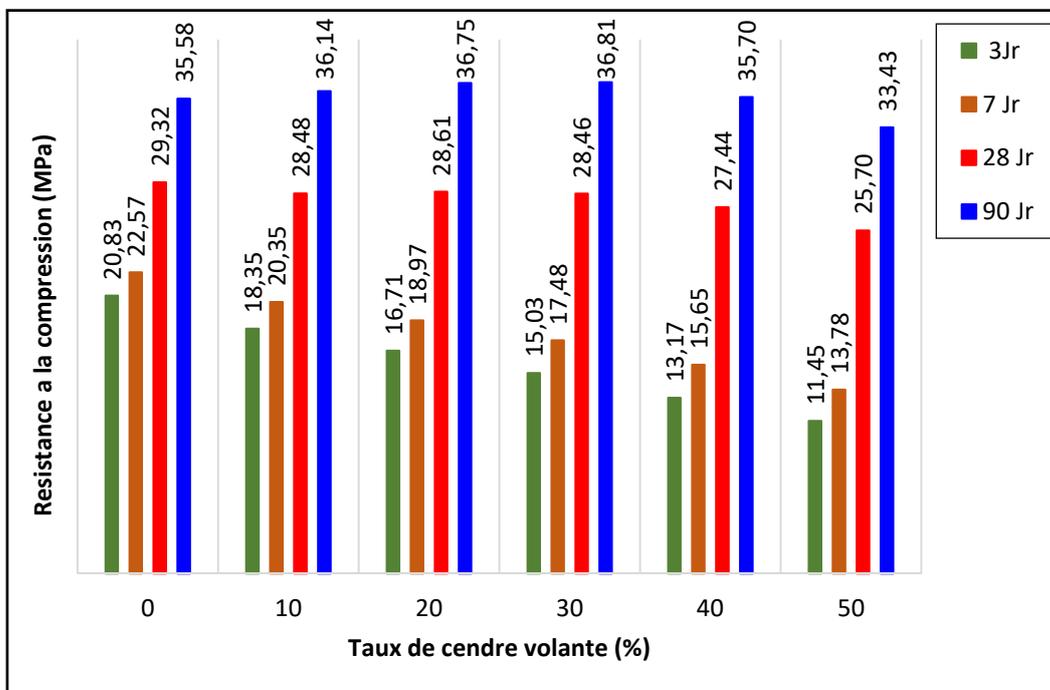
Les valeurs limites de l'indice D pour le fonctionnement correct du modèle **M2** sont données au tableau 6.1. La figure 6.6 montre l'effet de la classe de la cendre volante (F et C) en utilisant le modèle **M2** par la variation du paramètre D. Deux valeurs représentatives du paramètre D ont été choisies, $D = 5$ pour la classe C, et $D = 25$ pour la classe F.

Selon la Figure 6.6, Les bétons contenant des cendres volantes de la Classe F (Figure 6.6 (a)) développent des résistances moins que celles des bétons aux cendres volantes de Classe C (Figure 6.6 (b)) à 3 et 7 jours (au jeune âge). Tandis qu'au-delà de 28 jours, les résistances à la compression des bétons des CV de type F sont plus élevés par rapport aux

bétons à base de CV de type C. Ces résultats sont en concordance avec les résultats trouvés dans la littérature, cela montre la capacité du modèle M2 d'étudier l'effet de la classe des cendres volantes sur le béton.



a) – D = 25 (classe F)



b) – D = 5 (classe C)

Figure 6.6 – Effet du type des cendres volantes sur le développement de la résistance

6.3.3 Formulation des Bétons aux cendres volantes vis-à-vis la résistance et l'ouvrabilité « M3 »

Le modèle **M3** permet l'optimisation du mélange de béton à partir des deux propriétés essentielles du béton ; l'ouvrabilité et la résistance à la compression. Le modèle composé d'une combinaison d'entrée qui est « la résistance à la compression, l'ouvrabilité, l'indice D, le taux de substitution et le rapport Gravier/Granulats », chaque combinaison donne une composition de béton, qui est définie par la quantité de liant, de granulats, du rapport E/L. On a varié la combinaison d'entrée proposée, plusieurs formulations ont été obtenues par le modèle développé, les résultats obtenus sont représentés dans les tableaux de 6.5 à 6.10.

Tableau 6.5 – Formulations obtenus par modèle M3 pour un rapport $G/(G+S) = 0.55$, Indice D = 25 (CV classe F) et une ouvrabilité de 10 cm

Résistance f_{c28} (MPa)	Pourcentage d'ajout (%)	Quantité ajout (kg/m^3)	Quantité Ciment (kg/m^3)	Quantité Eau (kg/m^3)	Quantité Sable (kg/m^3)	Quantité Gravier (kg/m^3)
10	0	0	255	167	1074	879
20		0	285	172	1064	871
30		0	319	174	1053	862
40		0	350	172	1042	853
10	10	27	241	171	1058	866
20		29	259	172	1054	862
30		31	281	172	1048	857
40		34	307	168	1039	850
10	20	54	215	169	1059	867
20		58	231	168	1056	864
30		63	254	166	1048	858
40		69	277	161	1039	850
10	30	82	192	165	1060	867
20		89	208	163	1055	863
30		98	229	158	1046	856
40		106	246	152	1038	849
10	40	115	172	160	1057	865
20		125	188	155	1050	859
30		136	203	148	1041	852
40		142	213	142	1036	848

Tableau 6.6 – Formulations obtenus par modèle M3 pour un rapport $G/(G+S) = 0.6$,
Indice D =25 (CV classe F) et une ouvrabilité de 10 cm

Résistance fc28 (MPa)	Pourcentage d'ajout (%)	Quantité ajout (kg/m ³)	Quantité Ciment (kg/m ³)	Quantité Eau (kg/m ³)	Quantité Sable (kg/m ³)	Quantité Gravier (kg/m ³)
10	0	0	263	169	1166	778
20		0	299	174	1152	768
30		0	336	176	1138	759
40		0	370	173	1126	751
10	10	28	253	172	1146	764
20		31	278	174	1137	758
30		35	311	174	1124	749
40		38	343	168	1112	741
10	20	57	228	171	1145	763
20		63	252	172	1136	758
30		70	281	169	1124	750
40		77	309	160	1112	741
10	30	88	205	169	1144	763
20		97	226	167	1135	757
30		108	251	161	1123	749
40		117	273	151	1112	742
10	40	121	182	164	1142	761
20		134	201	159	1132	755
30		147	220	150	1121	747
40		155	233	142	1114	743

Tableau 6.7 – Formulations obtenus par modèle M3 pour un rapport $G/(G+S) = 0.65$,
Indice D =25 (CV classe F) et une ouvrabilité de 10 cm

Résistance fc28 (MPa)	Pourcentage d'ajout (%)	Quantité ajout (kg/m ³)	Quantité Ciment (kg/m ³)	Quantité Eau (kg/m ³)	Quantité Sable (kg/m ³)	Quantité Gravier (kg/m ³)
10	0	0	266	169	1260	679
20		0	309	175	1241	668
30		0	355	176	1221	657
40		0	395	171	1205	649
10	10	29	260	172	1235	665
20		32	287	174	1224	659
30		37	331	172	1203	648
40		42	378	163	1181	636
10	20	59	236	172	1233	664
20		66	265	172	1220	657
30		76	305	167	1199	646
40		86	344	154	1179	635
10	30	91	213	171	1230	662
20		103	241	168	1215	654
30		118	276	159	1195	644
40		131	306	144	1178	634
10	40	127	191	167	1225	660
20		144	216	160	1210	652
30		162	243	148	1192	642
40		175	262	134	1180	635

Tableau 6.8 – Formulations obtenus par modèle M3 pour un rapport $G/(G+S) = 0.55$,
Indice $D = 5$ (CV classe C) et une ouvrabilité de 10 cm

Résistance fc28 (MPa)	Pourcentage d'ajout (%)	Quantité ajout (kg/m ³)	Quantité Ciment (kg/m ³)	Quantité Eau (kg/m ³)	Quantité Sable (kg/m ³)	Quantité Gravier (kg/m ³)
10	0	0	255	167	1074	879
20		0	285	172	1064	871
30		0	319	174	1053	862
40		0	350	172	1042	853
10	10	26	238	168	1071	876
20		30	266	172	1061	868
30		33	296	173	1050	859
40		36	322	170	1040	851
10	20	55	219	168	1070	875
20		62	246	170	1058	866
30		68	272	169	1047	856
40		72	289	166	1039	850
10	30	85	199	166	1068	873
20		96	223	168	1055	863
30		104	242	165	1044	854
40		108	251	162	1039	850
10	40	118	177	164	1063	870
20		131	196	163	1050	859
30		138	207	160	1042	853
40		141	212	158	1038	849

Tableau 6.9 – Formulations obtenus par modèle M3 pour un rapport G/ (G+S) = 0.60, Indice D =5 (CV classe C) et Ouvrabilité de 10 cm.

Résistance fc28 (MPa)	Pourcentage d'ajout (%)	Quantité ajout (kg/m ³)	Quantité Ciment (kg/m ³)	Quantité Eau (kg/m ³)	Quantité Sable (kg/m ³)	Quantité Gravier (kg/m ³)
10	0	0	263	169	1166	778
20		0	299	174	1152	768
30		0	336	176	1138	759
40		0	370	173	1126	751
10	10	28	249	171	1161	774
20		31	283	175	1146	764
30		35	317	174	1132	755
40		38	345	170	1120	747
10	20	58	231	171	1158	772
20		66	263	174	1142	762
30		73	291	171	1128	752
40		78	311	166	1119	746
10	30	90	211	171	1154	770
20		102	239	171	1138	759
30		111	260	167	1126	751
40		116	271	162	1121	747
10	40	125	188	168	1150	767
20		140	210	166	1135	757
30		149	223	162	1126	751
40		152	228	159	1123	749

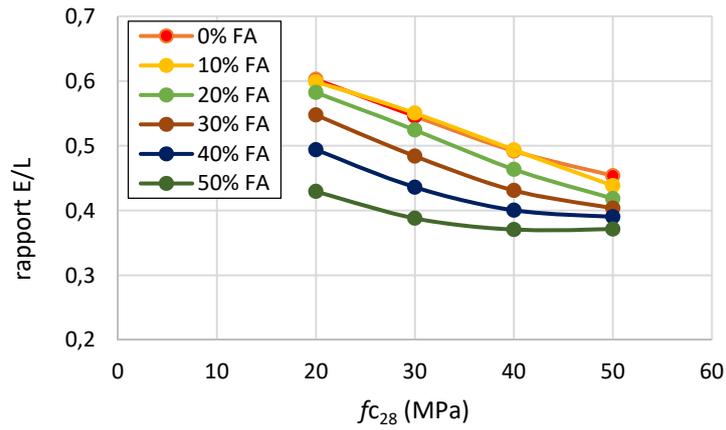
Tableau 6.10 – Formulations obtenus par modèle M3 pour un rapport G/ (G+S) = 0.65, Indice D =5 (CV classe C) et une ouvrabilité de 10 cm.

Résistance fc28 (MPa)	Pourcentage d'ajout (%)	Quantité ajout (kg/m ³)	Quantité Ciment (kg/m ³)	Quantité Eau (kg/m ³)	Quantité Sable (kg/m ³)	Quantité Gravier (kg/m ³)
10	0	0	266	169	1260	679
20		0	309	175	1241	668
30		0	355	176	1221	657
40		0	395	171	1205	649
10	10	28	254	171	1252	674
20		33	296	176	1231	663
30		38	339	174	1211	652
40		41	373	166	1195	644
10	20	60	238	173	1247	671
20		70	278	175	1225	659
30		78	314	170	1205	649
40		84	338	162	1193	643
10	30	94	220	173	1241	668
20		109	255	172	1219	656
30		121	282	165	1202	647
40		127	296	158	1195	643
10	40	133	200	171	1234	665
20		151	227	167	1214	653
30		163	244	160	1202	647
40		166	249	156	1199	646

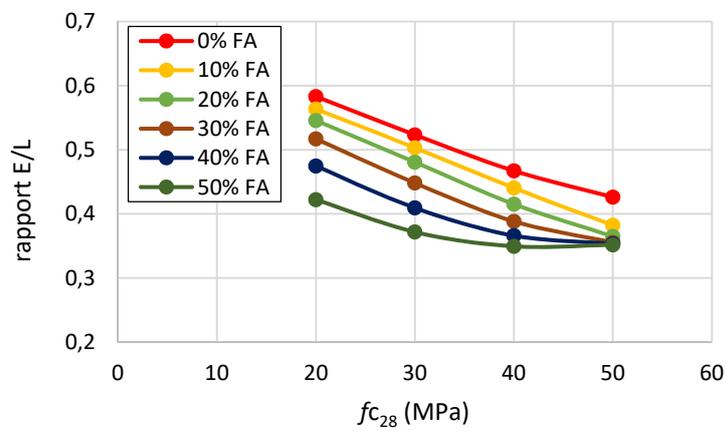
A partir des tableaux de 6.5 à 6.10, on constate la facilité de l'obtention d'un nombre importants de formulation à partir du modèle **M3**. Il permet de diminuer considérablement le nombre d'essais effectués au laboratoire. Cela montre l'importance et l'utilité de ce type de modèles qui facilitent la tâche des chercheurs en plus des avantages économique, environnementale...etc.

6.3.3.1 Effet du rapport E/L sur la résistance

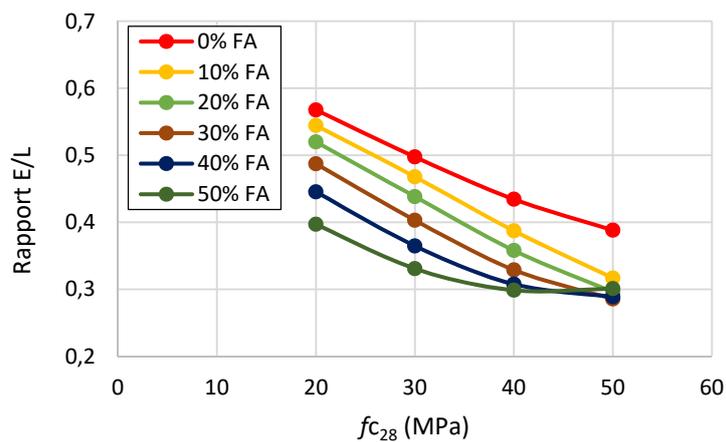
En suivant la même méthodologie adoptée pour le développement des Modèles **M1** et **M2**, une étude paramétrique a été menée pour comprendre le fonctionnement du modèle de formulation **M3** afin de tester la capacité de généralisation de ce dernier. Les résultats du rapport E/L et le liant obtenus en fonction de la résistance à la compression sont représentés sur les figures de 6.7 à 6.8 respectivement.



a) - G/Gr = 0.55

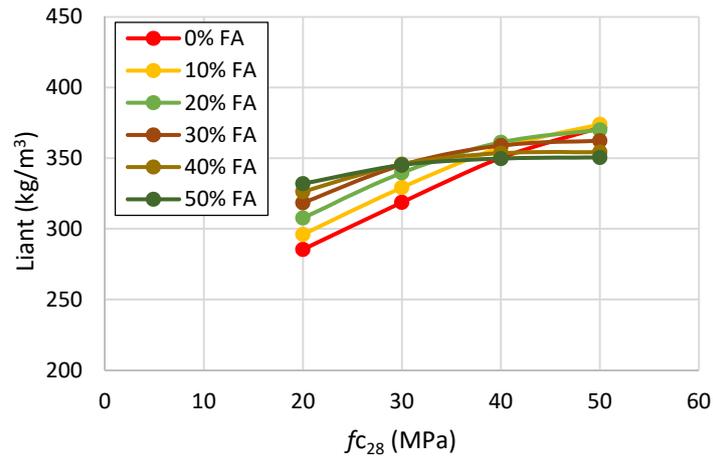


b) - G/Gr = 0.60

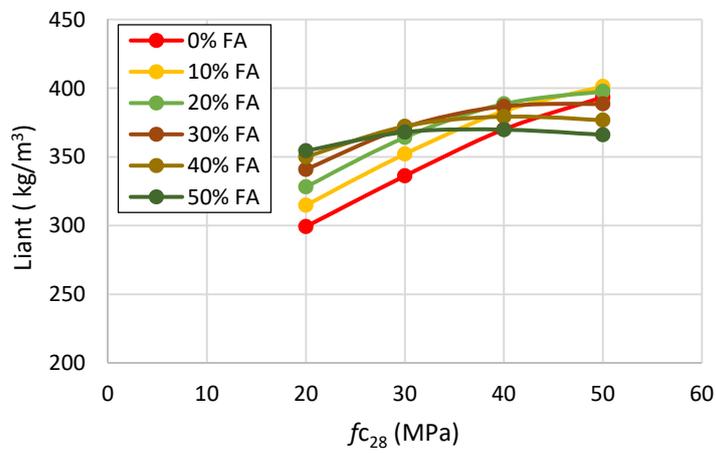


c) - G/Gr = 0.65

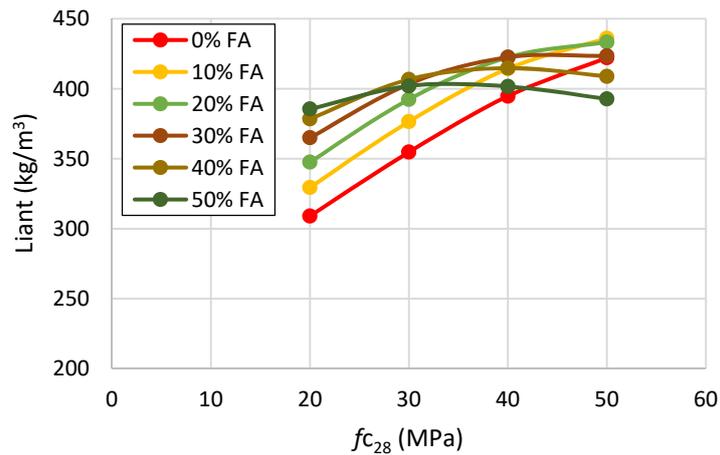
Figure 6.7 – Variation du rapport E/L en fonction de la résistance à 28 jours pour différent rapport G/Gr avec D =25 et Ouvrabilité = 10cm



a) – G/Gr = 0.55



b) – G/Gr = 0.60



c) – G/Gr = 0.65

Figure 6.8 – Variation du liant en fonction de la résistance à 28 jours pour différent rapport G/Gr avec D =25 et Ouvrabilité = 10cm

D'après la figure 6.7, on constate la diminution du rapport E/L lorsque la résistance à la compression augmente. Cette dernière est en croissance avec l'augmentation du liant selon la figure 6.8 pour tous les rapports G/Gr étudiés par le modèle **M3**.

La figure 6.7 (b) montre la variation du rapport E/L en fonction de la résistance à la compression pour $G/Gr = 0.60$, on observe que pour aller de 20 à 50 MPa on doit diminuer le rapport E/L de 0.6 à 0.43 pour le béton témoin (0% CV) et augmenter la quantité du liant de 300 à 390 kg/m³ comme le montre la figure 6.8.

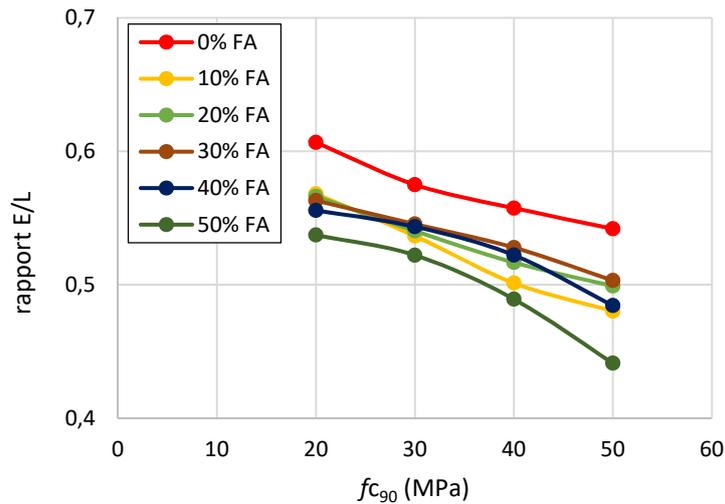
Les mêmes remarques ont été faites pour les autres mélanges de bétons contenant des dosages de cendres volantes variant de 10 à 50 %. La résistance croit en même temps que le dosage en ciment, et elle décroît lorsque le dosage en Eau augmente. Ceci prouve que le modèle développé dans cette étude corrobore les résultats obtenus par plusieurs chercheurs dans le domaine de la technologie de béton.

6.3.3.2 Effet du type de cendres volantes sur la résistance à la compression

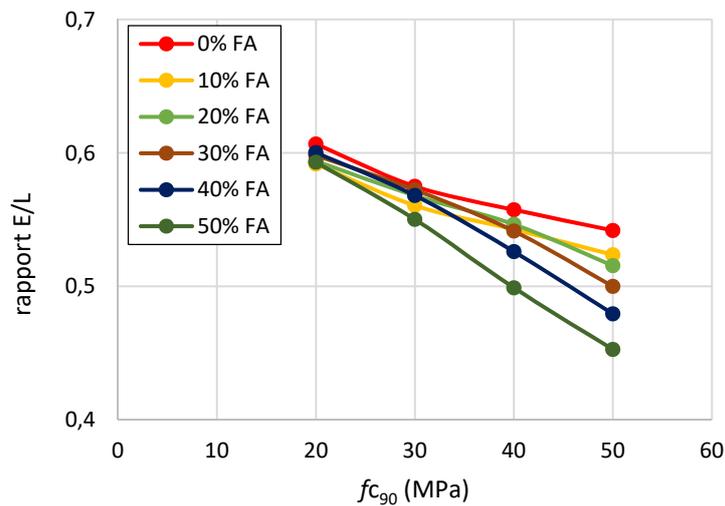
La figure 6.9 présente la variation du rapport E/L en fonction de la résistance à la compression pour deux valeurs de l'indice «**D**» de la classe des cendres volantes.

D'après la figure 6.9– (a), pour toutes les valeurs de résistances étudiées, on observe que les bétons contenant de 10 à 50% de cendres volantes de classe F, nécessitent un rapport E/L inférieur par rapport à celui du béton témoin (0% de CV).

On remarque que la courbe de l'effet du rapport E/L en fonction de la résistance à la compression du béton témoin est plus éloignée par rapport aux courbes des bétons contenant différents dosages de CV de classe F (Figure 6.9(a)). Par contre, pour les cendres volantes de Type C le dosage de CV n'influe pas de manière significative sur la valeur du rapport E/L pour les résistances inférieures à 40 MPa.



a) – D = 25 (CV classe F)



b) – D = 5 (CV classe C)

Figure 6.9 – Variation de rapport E/L en fonction de la résistance à 90 jours pour D =25 et 5 avec une Ouvrabilité de 10cm

6.4 Conclusion

Dans ce présent chapitre une étude de sensibilité a été faite dans le but de simuler l'impact des différents paramètres d'entrées des modèles RNAG développés pour prédire la résistance à la compression du béton à un âge donné à l'aide des modèle de prévision **M1** et **M2** et de formulation des bétons contenant des cendres volantes par le modèle **M3**.

Dans cette analyse, un paramètre a été varié, tandis que les autres paramètres sont maintenus constants afin d'examiner la capacité des modèle à conserver les lois de comportement du béton connus dans la technologie de béton

Les modèles **M1**, **M2** et **M3** ont montré une très bonne fiabilité, toutes les relations analysées dans cette étude comme les effets du rapport E/L, de l'âge, du type des cendres volantes, du taux de substitution de CV, sont bien conservées et tous les résultats obtenus par les modèles développés sont en concordance avec les constatations disponibles dans la littérature.

#

Conclusions Générales et Recommandations

#

#

Conclusions générales

Les développements récents de la technologie de l'information ont eu un impact considérable sur la technologie du béton et en particulier sur l'optimisation et la prévision de ses performances. La formulation des bétons est un processus très important, avant d'aborder la fabrication du béton, il faut se rappeler qu'il s'agit d'un matériau obtenu en mélangeant un ensemble de constituants présentant des états et des caractéristiques très différents.

Les composants de béton influent directement et énormément sur les propriétés essentielles du béton tels que l'ouvrabilité, la résistance à la compression et la durabilité. Le problème est d'établir d'identifier les relations entre les constituants et les propriétés du béton. Plusieurs chercheurs s'intéressent aux problèmes de formulation de béton. Les techniques d'intelligence artificielle (IA), les réseaux de neurones (RNs), les algorithmes génétiques (AG) et la logique floue (LF) sont largement utilisés en génie civil, ces techniques sont considérées comme des outils utiles, puissants et capables de résoudre plusieurs types de problèmes, et en particulier en technologie de béton.

Bien que les études et les recherches au sujet de formulation des bétons sont limitées dans la majorité des cas à des approches statistiques (empiriques, de régression et probabilistes). Les réseaux de neurones artificiels constituent actuellement l'approche la plus utilisée. Ils sont conçus avec des modèles mathématiques très simplifiés plus ou moins inspirés du fonctionnement cérébral de l'être humain et sont devenus aujourd'hui, un des sujets de recherche les plus connus avec leurs capacités d'apprentissage, de généralisation, de traitement parallèle et d'approximation. Ces propriétés ont rendu les réseaux de neurones un outil puissant concernant tous les domaines. En Génie Civil, un certain nombre de recherches montre clairement le potentiel et les possibilités d'application des modèles de RNAs pour la résolution de plusieurs problèmes.

Il est à noter, que les RNAs présentent des avantages et des limites. Leur limite majeure est le problème de minima-locaux. Pour cela, l'intégration d'un AG a été effectuée afin d'optimiser les poids de connexion et les seuils au niveau de chaque neurone de l'architecture du réseau RN pour minimiser l'erreur, accélérer la convergence et permettre une meilleure généralisation du système.

La diversité des bétons actuels, aux propriétés extrêmement variables, ne permet pas d'imaginer un principe de formulation commun. La complexité des problèmes de formulations

et de la prévision des propriétés des bétons à l'état frais ou durci, surtout avec les spécifications et les exigences actuels, nécessite un outil très performant pour traiter de tels problèmes.

L'objectif principal de cette étude est de développer un nouveau système de formulation des bétons avec ajouts cimentaires (pouzzolane naturelle et cendres volantes).

Une nouvelle structure évoluée d'hybridation a été d'abord développée puis intégrée à un réseau de neurones avant son apprentissage pour optimiser son architecture en termes de poids de connexion et des biais qui sont souvent générés aléatoirement. Ce modèle a prouvé qu'il est plus performant et plus rapide en comparaison avec le RN seul. Ceci a été clairement montré en comparant les différents indicateurs de performance MSE, RMSE, MAPE et du coefficient de détermination R^2 pour le modèle hybride RNAG et le modèle RN seul.

A cause de la complexité du phénomène étudié, l'auto-validation de ces modèles basés sur ses critères est insuffisante. En conséquence, les modèles ont été validés expérimentalement à travers la réalisation d'un programme expérimental au laboratoire d'une part et par la confrontation avec d'autres modèles, proposés par les règlements, d'autre part. Les résultats de validation ont montré clairement que le modèle RNAG a donné des résultats très satisfaisants, avec des coefficients de détermination R^2 très élevés, de 0.93 et 0.94 pour les modèles de prévision M1 et M2 respectivement. Les résultats obtenus par les modèles M1 et M2 corroborent les résultats obtenus par l'ACI 209 et le CEB-FIP 1990.

De même, le modèle de formulation des bétons contenant des cendres volantes (M3) a montré de très bonnes performances avec des erreurs de 2, 4 et 6% pour les outputs du modèle : liant, rapport E/L et granulats, respectivement.

Les trois modèles développés ont été implémentés dans un système muni d'une interface utilisateur conviviale. Pendant une session interactive avec l'utilisateur, le système pourra facilement faire la prévision de la résistance à la compression pour des bétons aux pouzzolanes naturelles et les cendres volantes ainsi que l'optimisation de la formulation des bétons aux cendres volantes.

Recommandations

Il serait souhaitable que les modèles développés soient généralisés. D'une part, pour la formulation de béton contenant d'autres ajouts cimentaires comme le laitier, la fumée de silice. D'autre part, par une optimisation des performances des modèles élaborés par la combinaison des RNAs avec d'autres techniques de l'intelligence artificielle et les méthodes probabilistes.

En ce qui concerne un approfondissement des modèles développés, nous recommandons les points suivants :

- ✓ L'élargissement de la base de données par une mise à jour périodique ;
- ✓ l'utilisation d'autres techniques d'intelligence artificielle tel que : l'apprentissage profond (Deep learning), la logique floue, les systèmes experts, l'intelligence en essaim (swarm intelligence algorithms)...etc.
- ✓ l'application des techniques d'intelligence artificielle sur d'autres types de béton (béton à hautes performances, les bétons fibrés...etc).

Il serait, aussi, souhaitable d'étudier la durabilité du béton pour la prévision de la durée de vie des structures en prenant en compte les paramètres les plus importants comme la qualité de la mise en œuvre, la qualité des matériaux utilisés et les diverses conditions d'usage, d'exploitation et de maintenance.

#

Références Bibliographiques#

#

Références Bibliographiques

- ACI Committee 209, (2008) *Guide for modeling and calculating shrinkage and creep in hardened concrete* (ACI 209.2R-08).
- ACI Committee 232 (2003) *Use of fly ash in concrete*. ACI Manual of Concrete Practice 232.2R-03.
- Ahmad S, Azad AK, Loughlin KF, (2012) *Effect of the key mixture parameters on tortuosity and permeability of concrete*. J. Adv. Concr. Technol. Vol. 10, N° 3, pp.86-94.
- Akkurt S, Ozdemir S, Tayfur G, Akyol B, (2003), *The use of GA-ANNs in the modelling of compressive strength of cement mortar*. Cem. Concr. Res. Vol. 33, 973–979.
- Alajmi A, Wright J, (2014) *Selecting the most efficient genetic algorithm sets in solving building optimization problem*, Int. J. Sustain. Built. Environ. Vol. 3 N° 1, pp.18–26.
- Al-Amoudi OSB, Maslehuddin M, Asi IM, (1996) *Performance and correlation of the properties of fly ash cement concrete*. Cem. Concr. Aggreg., Vol. 18, pp.71–77.
- Belalia Douma, O, Boukhatem B, Ghrici M, Tagnit-Hamou A, (2016) *Prediction of properties of self-compacting concrete containing fly ash using artificial neural network*. Neural Comput. Appl. 1–12.
- Berry EE, Malhotra, V.M. (1986). “*Fly ash in concrete*”. Energy, Mines and Resources Canada, CANMET, Ottawa, Canada.
- Bilodeau A, Sivasundaram V, Painter KE, Malhotra VM, (1994) *Durability of concrete incorporating high volumes of fly ash from sources in the U.S*. ACI Mater. J. Vol. 91, pp.3–12.
- Boukhatem B, (2011), *Conception d’un système automatisé intégré de connaissances pour les bétons aux ajouts* (SAICBA), Thèse de Doctorat, Département de Génie Civil, Université de Blida, 167p
- Boukhatem B, Ghrici M, Kenai S, Tagnit-Hamou A, (2010) *Prévision de l’efficacité des cendres volantes dans le béton par l’utilisation d’un réseau de neurones artificiel*. XXVIIIèmes Rencontres Univ. Génie Civ. La Bourboule, France., pp.499–508.
- Boukhatem B, Kenai S, Hamou AT, Ziou D, Ghrici M, (2012) *Predicting concrete properties using neural networks(NN) with principal component analysis (PCA) technique*. Comput. Concr. Vol. 10, pp.557–573.
- Bouzoubaâ N, Fournier B, (2003) *Optimization of fly ash content in concrete: Part I: Non-air-entrained concrete made without superplasticizer*. Cem. Concr. Res. Vol. 33, pp.1029–1037.

- Bremner TW, Thomas MDA, (2004), *Learning module on traditional and non- traditional uses of coal combustion products (CCP)*. Association of Canadian Industries Recycling Coal Ash (CIRCA).
- Chandwani V, Agrawal V, Nagar R, (2015) *Modeling slump of ready mix concrete using genetic algorithms assisted training of artificial neural networks*. Expert Syst. Appl. Vol. 42, pp.885–893.
- Chang YT, Lin J, Shieh JS, Abbod MF, (2012) *Optimization the initial weights of artificial neural networks via genetic algorithm applied to hip bone fracture prediction*. Adv. Fuzzy Syst. 9p.
- Chindaprasirt P, Chotithanorm C, Cao HT, Sirivivatnanon V, (2007) *Influence of fly ash fineness on the chloride penetration of concrete*. Constr. Build. Mater. Vol. 21, pp.356–361.
- Chopra P, Sharma RK, Kumar M, (2016), *Prediction of compressive strength of concrete using artificial neural network and genetic programming*. Adv. Mater. Sci. Eng., 10p.
- De Larrard F, (1999) *Structures granulaires et formulation des betons, modern concrete Technology Series, Londres, 421p*.
- Delphi 10, (2014) Developer's Guide, Borland Software Corporation, USA, p. 1106.
- Demuth H, Beale M, (2014). *Neural Network Toolbox for Use with Matlab--User'S Guide*.
- Dernoncourt F, (2011) *Introduction to Fuzzy Logic*. Massachusetts Institute of Technology, 14p.
- Donald B, (2006) *The durability of concrete containing high levels of fly ash*, Thesis, Masters of Science in Engineering, 101p.
- Dreux G, (1982) *Composition des bétons, Béton hydraulique*. Techniques de L'ingénieur C2220, 14p.
- Dreyfus G, (2004) *Réseaux de neurones : méthodologie et applications*. Ed. Eyrolles. 436p.
- Dreyfus G, Martinez JM, Samuelides M, Mirta BG, Badran F, Thiria S, Hérault L, (2002) *Réseau de neurones-Méthodologie et application*, Ed. Eyrolles, 386p.
- EN N, (2000). 206-1. *Concrete Specification, Performance, Production and Conformity*.
- Felekoglu B, (2006) *Utilisation of Turkish fly ashes in cost effective HVFA concrete production*. Fuel , Vol. 85, pp.1944–1949.
- Flood I, (2008) *Towards the next generation of artificial neural networks for civil engineering*, Advanced Engineering Informatics, Vol. 22, pp.4-14.
- Galushkin AI, (2007) *Neural Networks Theory*, 2007 edition. ed. Springer, Berlin ; New York.

- Gardner NJ, (1990) *Effect of temperature on the early-age properties of type i, type ii, and type III/fly ash concretes with temperature*. Mater. J. Vol. 87, pp.68–78.
- Gen M, Cheng R, (1999) *Genetic algorithms and engineering optimization*, 1 edition. ed. Wiley-Interscience, New York.
- Gen M, Cheng R, Lin L, (2008) *Network models and optimization: multiobjective genetic algorithm approach*. Softcover reprint of hardcover 1st ed. 2008. ed. Springer London Ltd, London.
- Goldberg DE, (1989) *Genetic algorithms in search, optimization, and machine learning*. 1st Ed.. Addison-Wesley Professional, Reading, Mass.
- Gopalan MK, (1995) *Efficiency, skin strength and sorptivity of fly ash concretes*. Mater. Struct. Vol. 28, pp.235–240.
- Gopalan MK, Haque MN, (1987) *Effect of curing regime on the properties of fly-ash Concrete*. Mater. J. Vol. 84, pp.14–19.
- Haykin S, (1994) *Neural Networks: A Comprehensive Foundation*, 1st Ed. Prentice Hall, New Jersey, USA.
- Hobbs DW, (1983) *Influence of fly ash on the workability and early strength of concrete*. Proceedings, 1st International Conference on the Use of Fly Ash, Silica Fume, Slag and other Mineral By-Products in Concrete. ACI SP – 79, pp. 289-306, Detroit, Michigan
- Holland JH, (1992) *Adaptation in natural and artificial systems: an introductory analysis with applications to biology control, and artificial intelligence*, Reprint Edition. Bradford Book, Cambridge, Mass.
- Hossain KMA, Lachemi M, (2006) *Development of volcanic ash concrete: strength, durability, and microstructural investigations*, ACI Materials Journal, Vol. 103, pp.11-17.
- Houssou M, (2005) *Optimisation de la structure des réseaux de neurones par algorithmes genetiques*, Thèse de Doctorat, Université de Boumerdes, 99 p.
- Ji T, Lin T, Lin X, (2006) *A concrete mix proportion design algorithm based on artificial neural networks*. Cem. Concr. Res. Vol. 36, pp.1399–1408.
- Jiang J, (2013) *BP Neural network algorithm optimized by genetic algorithm and its simulation*. Int. J. Comput. Sci. Vol. 10, N° 2, pp.516–519.
- Jiang LH, Malhotra VM, (2000) *Reduction in water demand of non-air-entrained concrete incorporating large volumes of fly ash*. Cem. Concr. Res. Vol. 30, pp.1785–1789.
- Joshi RC, Lohtia RP, (1997) *Fly ash in concrete – production, properties and uses*. Advances in Concrete Technology Volume 2. Gordon and Breach Science Publishers, Printed in India.

- Kaid N, Cyr M, Khelafi H, Gouf N (2009) *Caractéristiques mécaniques de bétons contenant une pouzzolane naturelle face aux attaques à l'eau de mer et aux sulfates*, 1st International Conference on Sustainable Built Environment Infrastructures in Developing Countries ENSET,Oran, 8p.
- Kang CC, Chuang YJ, Tung KC, Chao CC, Tang CY, Peng SC, Wong DSH, (2011) *A genetic algorithm-based Boolean delay model of intracellular signal transduction in inflammation*. BMC Bioinformatics 12 Suppl 1, S17.
- Kisi O, Shiri J, et Tombul M, (2013) *Modeling rainfall-runoff process using soft computing techniques*, Comput. Geosci., Vol. 51, pp.108-117.
- Koehn, P (1994) *Combining genetic algorithms and neural networks: the encoding problem*, PhD thesis, University of Tennessee, Knoxville, 105 p.
- Konar A, (1999) *Artificial intelligence and soft computing: behavioral and cognitive modeling of the human brain*, 1st Ed. CRC Press, Boca Raton, Fla.
- Lim CH, Yoon YS, Kim JH (2004) *Genetic algorithm in mix proportioning of high-performance concrete*. Cem. Concr. Res. Vol. 34, pp.409–420.
- Lu P, Chen S, Zheng Y, (2012) *Artificial intelligence in civil engineering*, Math. Probl. Eng. 22p.
- Lutton E, (1999), *Algorithmes génétiques et fractales*, Habilitation à Diriger des Recherches, Université de Paris XI Orsay.
- McCarthy MJ, Dhir RK, (2005) *Development of high volume fly ash cements for use in concrete construction*. Fuel, International Ash Utilization Symposium, Vol. 84, pp.1423–1432.
- Minsky M, (2007), *The emotion machine; commonsense thinking, artificial intelligence, and the future of the human mind*, Simon & Schuster, 400p.
- Mirza S, Lacroix EA, (2002) *Comparative study of strength-computation methods for rectangular reinforced concrete columns*, ACI Structural journal, Vol. 99, pp.399-400
- Model Code (2010), *The fib Model Code for Concrete Structures 2010*, Comité Euro-International du Béton. fib Bulletin N °65, 2012, 350p.
- Mordjaoui M, (2008) *Modélisation des effets électromagnétiques « apport de la logique floue et neuro-floue*, Thèse de Doctorat, Département d'électronique, Université de Batna, 191p.
- Naseer A, Jabbar A, Akhtar NK, Ali Q, Hussain Z, Mizra J, (2008) *Performance of Pakistani volcanic ashes in mortars and concrete*, Civil Engineering, Vol. 35, pp.1435-1445.
- Nehdi, M., and Nikopour, H., (2011), *Modeling shear capacity of reinforced concrete beams using genetic algorithms*. Materials and Structures, Vol.44, pp.1249–1258

- Neural Network and Genetic algorithms for user with MATLAB 8, The Math Works Inc, Prentice Hall, 2014.
- Neville AM, (1995) *Formulation d'un béton*, in "Propriete des Beton", Ed. Eyrolles, pp.695-738.
- Oh JW, Lee IW, Kim JT, Lee GW, (1999) *Application of neural networks for proportioning of concrete mixes*. Mater. J. Vol. 96, pp.61–67.
- Olawuyi BJ, Olusola KO, (2010) *Compressive strength of volcanic ash/ordinary Portland cement laterized concrete*, Civil Engineering Dimension, Vol. 12, pp.23-28.
- Ozbay E, Gesoglu M, Güneyisi E, (2008) *Empirical modeling of fresh and hardened properties of self-compacting concretes by genetic programming*. Constr. Build. Mater., Vol. 22, pp.1831–1840.
- Öztaş A, Pala M, Özbay E, Kanca E, Çağlar N, Bhatti MA, (2006) *Predicting the compressive strength and slump of high strength concrete using neural network*. Constr. Build. Mater. Vol. 20, pp.769–775.
- Parizeau M (2004) *Réseaux de neurones*, Université de Laval, 117p.
- Pekmezci BY and Akyuz S (2004) *Optimum usage of a natural pozzolan for the maximum compressive strength of concrete*, Cement and Concrete Research, Vol. 34, pp.2175–2179.
- Ramezani pour A.A. (1987), *Engineering properties and morphology of pozzolanic cement-concrete*, PhD Thesis, University of Leeds, UK, 310p.
- Ramezani pour AA, Malhotra VM, (1995) *Effect of curing on the compressive strength, resistance to chloride-ion penetration and porosity of concretes incorporating slag, fly ash or silica fume*. Cem. Concr. Compos. Vol. 17, pp.125–133.
- Ravindrarajah, R.S., Tam, C.T., 1989. Properties of concrete containing low-calcium fly ash under hot and humid climate. ACI Special Publication, Vol. 114, pp.139–156.
- Rebouh R, (2011) *Formulation des bétons avec ajout par l'utilisation des réseaux de neurones*, Mémoire de Master, université de Chlef, 117p.
- Rebouh R, Boukhatem B, Ghrici M, Tagnit-Hamou A, (2017) *A practical hybrid NNGA system for predicting the compressive strength* A practical hybrid NNGA system for predicting the compressive strength, Constr. Build. Mater., Vol. 149, pp.778–789.
- Rumelhart, D. E., Hinton, G. E., and Williams, R. J. (1986). *Learning internal representations by error propagation*. In Parallel Distributed Processing,
- Sarıdemir M, (2009) *Prediction of compressive strength of concretes containing metakaolin and silica fume by artificial neural networks*. Adv. Eng. Softw. Vol. 40, pp.350–355.

- Shafiq N, Nuruddin MF, Kamaruddin I, (2007) *Comparison of engineering and durability properties of fly ash blended cement concrete made in UK and Malaysia*. Adv. Appl. Ceram. Vol. 106, pp.314–318.
- Shannag JM, Yeginobali A, (1995) *Properties of pastes, mortars and concretes containing natural pozzolan*, Cement and Concrete Research, Vol. 25, N° 3, pp. 647-657.
- Simčič T, Pejovnik S, De Schutter G, Bosiljkov VB, (2015) *Chloride ion penetration into fly ash modified concrete during wetting–drying cycles*. Constr. Build. Mater., Vol. 93, pp.1216–1223.
- Sonebi M, Cevik A, (2009) *Genetic programming based formulation for fresh and hardened properties of self-compacting concrete containing pulverised fuel ash*. Constr. Build. Mater., Vol. 23, pp.2614–2622.
- Steeb, W.H., Hardy, Y., Stoop, R., (2005), *Genetic algorithms in the nonlinear workbook*, 3rd Ed. World Scientific Publishing. 588 p.
- Tagnit-Hamou A, Petrov N, Luke K, (2003) *Properties of concrete containing diatomaceous earth*, ACI Materials Journal, Vol. 100, pp.73-78.
- Thomas MDA, (2007) *Optimizing the use of fly ash in concrete*, Portland Cement Association.
- Turanli L, Erdogan TY, (1999) *Investigation on the effect of natural pozzolan addition on compressive strength of Portland pozzolan cement*, Concrete Technology for Developing Countries 4th Conference, pp.169-176
- Uzal B, Turanli L, and Mehta, PK, (2007), *High-volume natural pozzolan concrete for structural applications*, ACI Materials Journal, Vol. 104, pp.535-538.
- Vidéla CC, Covarrubias JPT, Pascual, JMD, (1996) *Behaviour in extreme climates of concrete made with different types of cement*, in “Concrete in the Service of Mankind: Appropriate concrete technology” CRC Press, Vol. 3, pp.213-222.
- Woo SK, Song YC, Won JP, (2011) *Enhanced durability performance of face slab concrete in Concrete-Faced Rock-filled Dam using fly ash and PVA fibre*. KSCE J. Civ. Eng. Vol. 15, N° 5, pp.875-882.
- Yang, B.D.S., Park, S.K., and Lee, J.H., (2003), *A prediction on mix proportion factor and strength of concrete using neural network*, KSCE Journal of Civil Engineering, Vol. 7, N° 5, pp.525-536.

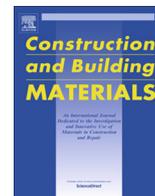
Annexe

#



Contents lists available at ScienceDirect

Construction and Building Materials

journal homepage: www.elsevier.com/locate/conbuildmat

A practical hybrid NNGA system for predicting the compressive strength of concrete containing natural pozzolan using an evolutionary structure

Redouane Rebouh^a, Bakhta Boukhatem^{a,b,*}, Mohamed Ghrici^a, Arezki Tagnit-Hamou^b^a Department of Civil Engineering, University of Chlef, Chlef, Algeria^b Department of Civil Engineering, University of Sherbrooke, Sherbrooke, QC, Canada

HIGHLIGHTS

- NNGA system is faster and performs better than NN model only.
- NNGA system can predict the compressive strength at any age with control of concrete mix design.
- NNGA system can be used to explore the effect of the concrete mixture and age on the compressive strength.
- A new graphical user interface is implemented to facilitate the use of the new NNGA prediction system.

ARTICLE INFO

Article history:

Received 9 January 2017

Received in revised form 16 May 2017

Accepted 21 May 2017

Keywords:

Natural pozzolan

Prediction

Compressive strength

Neural network

Genetic algorithms

Hybrid NNGA

ABSTRACT

Many researchers are interested in predicting the concrete compressive strength, resulting in quite a few linear and nonlinear regression equations. Alternatively, other models have been developed to produce more sophisticated systems by applying soft computing techniques, the majority of which have rarely been used beyond classic problems, such as function optimization or approximation by genetic algorithms (GAs), or neural networks (NNs). Our study proposes an evolutionary structure with a more complex NN in order to achieve the full potential of these techniques, which the genetics of neural systems promises to do. It consists of integrating a GA to optimize the connection weights for each neuron of an NN developed previously. The idea behind this combination is to develop an NNGA model prediction of the compressive strength of concrete containing natural pozzolan. Model learning and testing were first performed based on the back-propagation algorithm. Then, the model was optimized using the proposed evolutionary structure based upon GA. More than 400 experimental data collected from past studies were used in building this model. The hybrid NNGA model was compared with NN model using the same architecture, show that the NNGA is more performant and better than NN alone. The proposed hybrid model was also experimentally validated, very acceptable results with a high correlation coefficient R^2 equal to 0.93, yielding comparable results to those obtained by the ACI 209-08 and CEB-FIP models with R^2 values equal to 0.95 and 0.96, respectively. However, it can help to predict the compressive strength of a specified concrete mix at any age without knowing in prior the 28 days' compressive strength of this given concrete as it is the case in ACI 208-09 and CEB-FIB Codes. The main feature of this system is its flexibility to reduce significantly the scale of the experiment using a system graphical user interface.

© 2017 Elsevier Ltd. All rights reserved.

1. Introduction

Concrete manufacturers are under increasing time and cost constraints. These considerations have prompted several researchers to develop predictive models and computer-aided concrete mix design involving various approaches [1–3]. Predicting concrete

properties is important in the field of civil engineering. It is well known that compressive strength is considered one of the most critical and useful concrete properties. Conventional methods for assessing this property are fundamentally based on statistical analysis, which has involved many linear and nonlinear regression equations [4,5].

The literature on the early history of concrete technology describes two methods for developing a concrete maturity function, which subsequently led to the establishment of a maturity method, first introduced by Saul and Nurse in 1949 [6]. Later,

* Corresponding author at: Department of Civil Engineering, University of Sherbrooke, Sherbrooke, QC, Canada.

E-mail address: bakhta.boukhatem2@usherbrooke.ca (B. Boukhatem).

D'Aloia and Chanvillard [7] described a model for predicting concrete compressive strength at an early age by applying the equivalent time method. A number of models and methods have been developed from Feret's law and Bolomey's equation [8] based on the 28-day strength of concrete. Abrams [9] was the first to state that concrete strength depended on the water–cement ratio. For design purposes, most codes of practice do not consider the increase of strength beyond 28 days [10,11]. Moreover, other models have been developed to estimate the strength of concrete at later ages and have provided certain relationships for taking into consideration the use of mineral admixtures in concrete [12,13].

As an alternative, the artificial-intelligence approach—initially developed for conventional systems in physics and biology—has been a primary focus for IT research in almost every field of science and engineering. The best known of these techniques are neural networks (NNs), genetic algorithms (GAs), and fuzzy logic (FL). With their parallel processing and their neural-inspired mechanism, NNs infer emergent properties that solve problems once qualified as complex [14]. FL has been successfully used for modeling imprecise and uncertain knowledge [15], while GAs are optimization methods based on the genetic evolution of natural populations [16]. These techniques have provided convenient solutions to often highly specific civil-engineering problems [17].

More research based on NNs in the field of concrete technology were initially developed. These applications related mainly to mix proportioning [18], hydration [19], workability [20], compressive strength [21,22], and durability of concrete [21,23,24]. For FL, the first applications were made by the cement industry to intelligently control cement-grinding plants [25]. Some applications aimed at predicting the compressive strength of cements and concretes containing fly ash [26,27]. The GA approach has been used successfully in several engineering applications, but has only recently used for concrete optimization such as for modeling the compressive strength of ordinary and high-performance concrete [28–30]. The fresh and hardened properties of self-compacting concretes have also been predicted with GAs [31,32].

Many researchers are moving to adopt these techniques to build more sophisticated systems through synergistic combinations. In concrete technology, however, very little of this hybridization, especially for predicting concrete properties have been used [33].

Concrete compressive strength is the main property studied. Initially, a fuzzy NN model for predicting the compressive strength of concrete containing fly ash was developed [34]. In another application, GAs were combined with a neuro-fuzzy model for predicting the compressive strength of concrete containing fly ash [35]. Very recently, a genetic-programming NN model was developed for predicting compressive strength [29]. Most often, these applications have optimized a Backpropagation neural network in different ways.

Yet this application has rarely been used beyond the classic problems of optimizing functions using genetic algorithms with a very slow convergence or increasing/decreasing the number of NN neurons and their connectivity through a learning algorithm. In order to achieve the full potential of these techniques, which the genetics of neural systems promises to do, researchers must take up the challenge of developing networks more complex than the existing ones. The complexity, in this sense, requires a more complex and evolutionary network structure, such as those recently found in the genetics of the nervous system, which may indicate the potential evolutionary of intelligence [36]. This structure is based on the integration of a GA to optimize the connection weights and thresholds in each neuron of the NN architecture in order to minimize error, overcoming the convergence to local optima and improving its generalization.

In this study, this novel structure was developed by implementing an NNGA hybrid system for predicting the compressive

strength of concrete containing natural pozzolan and its evolution as a function of age from both the technical and economical points of view. Moreover, due to the complexity of the phenomenon, the self-validation of an NN model after being developed generally based on the criteria of minimizing the error and maximizing the correlation is insufficient. In this case, a sensitivity analysis and experimental validation are needed to evaluate models' performance. Eventually, a further comparison with other existing models is required.

Our research was divided into three main phases. The first phase was devoted to collecting and analyzing data on concretes containing natural pozzolans. The second and most important here, focused on developing the structure of the hybrid NNGA system by designing a new code based on the functions of the Neural Network Toolbox and MATLAB's genetic algorithm [37]. The complexity in programming this global code resides in combining both techniques, in particular, choosing performance functions, adjusting parameters, and execution time. In the third and last phase, an experimental program was carried out to validate the model and assess its performance. The results with the validated model were compared to that of other models such as the ACI and CEB models [10,11]. A parametric study was conducted to define the model's operating range. Finally, a user-friendly graphical interface was implemented based on DELPHI XE7 software [38] to make the model more convenient for users.

Therefore, the approach presented herein aimed at training a neural network optimized by genetic algorithms using the constituents of concretes containing natural pozzolan (water/binder, binder, percentage of natural pozzolan, superplasticizer, aggregates, and testing age) and properties (compressive strength) as outputs. Such a network can then be used to predict how various mix constituents will affect a given property. Further work is underway to use this approach for other types of concrete.

2. Genetic algorithm

A genetic algorithm (GA)—first formalized as an optimization method by Holland (1975) [16]—is a global heuristic optimization technique involving stochastic searches to solve highly dimensional, nonlinear, and noisy problems. It is based on the concepts of natural selection and natural genetics, and is recognized as a very efficient heuristic algorithm [39,40]. GAs are also considered as a problem-solving method and may be the most popular technique using evolutionary computation [41]. In recent years, GAs have been widely applied in various fields of engineering, yielding more accurate results than other techniques. These applications relate primarily to optimizing complicated digital functions, image processing, industrial control systems, learning neural networks, optimization of NN and VLSI circuits, and so on [42–44]. In civil engineering, for example, Lim et al. [45] have used GAs to optimize the formulation of HPC mixtures. GAs have also been used to optimize the artificial neural networks (ANNs) [46]. Currently, combining AI approaches has produced new systems for improving the Computer Integrated Knowledge System "CIKS" [47].

The principle underlying GAs is an iterative optimization procedure for specific problems expressed as an objective function (fitness function) based on evolving a population of solutions. With each iteration or generation, a new population with the same number of chromosomes is created. This generation consists of chromosomes better "adapted" to their environment, as represented by the fitness function. With successive generations, the chromosomes will tend towards the optimum of the fitness function. The creation of daughter populations involves applying the genetic operators of selection, crossover, and mutation (Fig. 1).

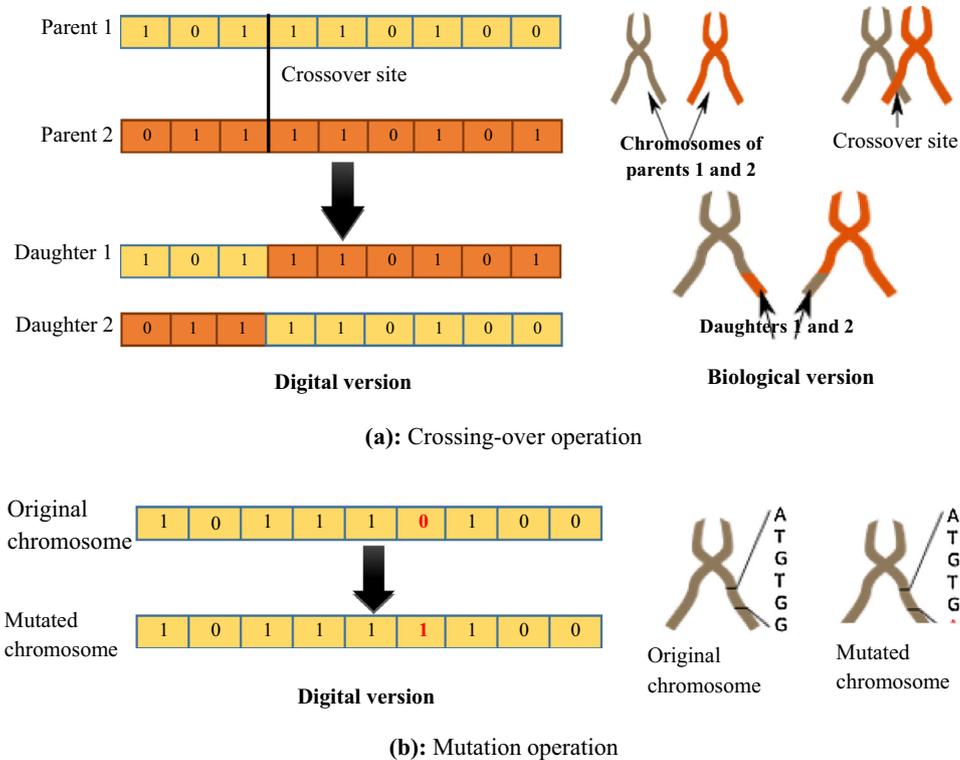


Fig. 1. Basic operators of genetic algorithms: (a) Crossover, (b) Mutation.

Selecting the best chromosomes is the first step in a genetic algorithm. During this operation the algorithm selects the relevant factors that optimize the function. The crossover is used to generate two new “daughter” chromosomes from two chromosomes selected as “parents,” while the mutation makes the inversion of one or more genes from one chromosome.

3. Neural networks

Artificial neural networks (ANNs), inspired by the functioning of biological nervous systems, are currently widely used for solving complex problems [14]. According to Haykin (1994), they are conceptually modeled on the human brain metaphor and are presented to resemble two aspects:

- Knowledge is acquired by the network through a learning process;
- Connections between neurons, known as weights, are used to store the knowledge [48].

Moreover, they perform outstandingly well as regression tools, especially when used for estimating functions in pattern recognition. They are collectively referred to as highly nonlinear and can handle complex interactions between input and output variables without any prior knowledge about the nature of these interactions [49].

A neural network is a system composed of a set of interconnected neurons. The back-propagation multilayer perceptron (BPMLP) is the most popular neural-network model, consisting of three adjacent layers: input, hidden, and output [14,50]. Each layer contains several neurons (Fig. 2).

The NN is trained by presenting a set of associated input–output data based on learning or a training process. The training process uses an algorithm allowing the NN to develop a function between the inputs and outputs. Generally, in a training process, neurons

receive input from the external environment (x_1, x_2, \dots, x_n) and transmit it to the neurons in the hidden layer, which are responsible for simple and useful mathematical calculations involving connection weight ($w_{11}, w_{12}, \dots, w_{1n}$), bias (b_1, b_2, \dots, b_n), and input values.

$$f(x) = \text{tansig}(n) = \frac{2}{(1 + e^{-2n} - 1)} \quad (1)$$

The results of these hidden neurons are passed through a threshold or activation function $f(x)$ (Eq. (1)) in each neuron (processing element), which limits neuron output to a minimum and maximum allowed bounds. Selecting this function appears to be a very important element in NNs, and nonlinear functions will often be required. Applying the function produces results. Thereafter, these results become the input to all neurons in the adjacent layer (the second hidden layer or output layer), and the calculation process is repeated through the layers until the output layer is reached.

The output values are produced with output neurons (y_1, y_2). At this stage, a value of output error is calculated between the outputs produced and the desired outputs in supervised learning. Generally, the training process is iterative and stops when a designed error is reached. Upon completion of a training process, the network should be able to give the solution(s) for any dataset based on the general architecture that has been developed.

4. Database

Data preparation is an important and critical step in NN modeling. The performance of the NN model is strongly related to the quality and distribution of the input data used and stored in a database. The experimental database in our study was based on experimental results on a concrete with natural pozzolans published worldwide in the literature from various sources. Based on global comparisons between datasets of various sizes, it was concluded

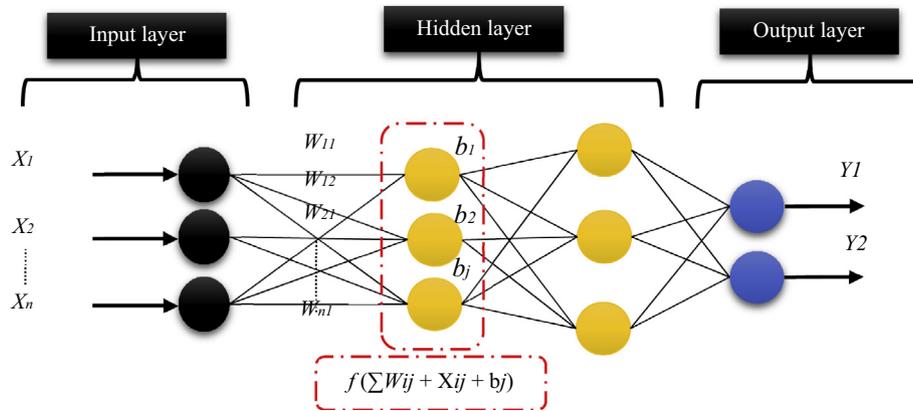


Fig. 2. Typical architecture of a multilayer perceptron neural network.

that NN generalization performance depends on the number of representative and reliable data appropriately analyzed.

4.1. Data Collection and variable selection

Data for ordinary concrete with natural pozzolan were extracted and compiled from research projects in the literature to populate the database. The database consists of a large number of datasets (11 research projects, carried out on concretes with natural pozzolan [51–61]). Table 1 presents the general details of the concretes assessed in this study.

About 700 concrete samples made with natural pozzolan and cured under normal conditions were assessed. Some of the samples were deleted from the data due to insufficient information, unexpected inaccuracies (aggregate size larger than 20 mm), special curing conditions, and so forth. The data variables selected are quantities of concrete mix constituents (cement, natural pozzolan, water, aggregates, and admixtures) with their corresponding property values (compressive strength at different ages), also known as input and output datasets, respectively. The compressive strengths were measured by testing concrete specimens of different sizes and shapes: cubes (10 × 10 × 10 cm and 15 × 15 × 15 cm) and cylinders (10 × 20 cm and 15 × 30 cm). All of these specimen types were converted into 15 cm cylinders according to accepted guidelines using the following empirical formulas (Eqs. (2) and (3)) [62].

$$f_a = f_{10} \left[0.58 + 0.42 \left(\frac{10}{a} \right)^{1/3} \right] \tag{2}$$

$$f_{cyl} = f_{15} \left[0.76 + 0.2 \log_{10} \left(\frac{0.95 f_{10}}{19.6} \right)^{1/3} \right] \tag{3}$$

Table 1 Database sources.

Data source	Number of data
Ramezaniipoor (1987) [51]	40
Shannagt & Yeginobali (1995) [52]	36
Vidéla et al. (1996) [53]	60
Turanli & Erdogan (1999) [54]	16
Pekmezci & Akyuz (2003) [55]	15
Tagnit-Hamou et al. (2004) [56]	15
Hossain et al. (2006) [57]	126
Uzal et al. (2007) [58]	20
Naseer et al. (2008) [59]	18
Kaid et al. (2009) [60]	48
Olawuyi & Olusola (2010) [61]	16
Total number of data	412

where f_a is cube the compressive strength, a is the cube size, f_{10} and f_{15} are 100 mm and 150 mm cube compressive strength respectively, f_{cyl} is the cylinder compressive strength.

4.2. Data-analysis division

The dataset used in the development of the neural-network-optimized-by-genetic-algorithm (NNGA) model assembled a total of 120 formulations or concrete compositions. In total, there are 412 values of compressive strength and workability. These data were used to check the model’s reliability in predicting the compressive strength of concrete mixes containing natural pozzolan at different ages (2, 7, 28, and 91 days). Table 2 provides the ranges of concrete constituents in the datasets.

The database was divided into three parts: training (70%), testing (20%), and validation (10%). The training dataset was used to train the NNGA model; the validation data set was used to stop the learning process; and all of the testing dataset was used to assess the performance of the NNGA model after completion of the training process. Each dataset consists of the factors affecting concrete mix design: compressive strength (f_{ct}), including testing age (t); water–binder ratio (W/B); amount of binder (B); replacement ratio with a natural pozzolan (NP); fine and coarse aggregates (sand and gravel); and superplasticizer (SP). After data division, the data were normalized between –1 and +1 before presentation to the NNGA model for consistency with the limits of tangent sigmoid transfer function used in hidden layers and the output layer.

5. Methodology of developing the NNGA model

Fig. 3 illustrates the methodology and development of the NNGA hybrid model. The process is organized around three main phases. The first phase is proposing the NN architecture and determining the learning parameters for a desired performance. The sec-

Table 2 Ranges of components of data sets.

Components	Minimum	Maximum	Average
Binder (kg/m ³)	290	501	391
Natural pozzolan (%)	0	50	20
W/B ratio	0.31	0.81	0.49
Gravel (kg/m ³)	789	1200	1030
Sand (kg/m ³)	408	892	700
Admixtures (%)	0	2.25	0.2
Age of testing (days)	2	90	40
Compressive strength (MPa)	3	64	29

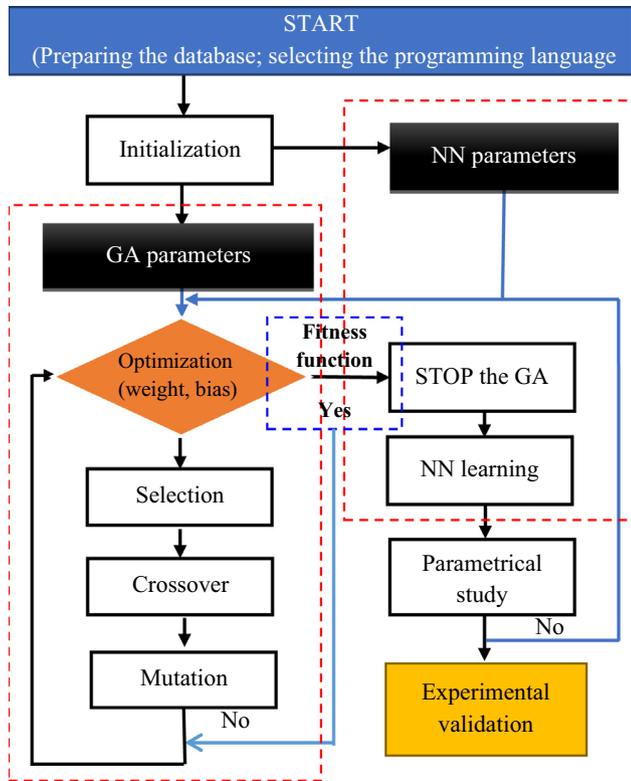


Fig. 3. NNGA system development.

Table 3
The values of training parameters used in the NN model.

NN parameters	Values and MATLAB nomenclature
Train function	trainlm (Levenberg–Marquardt)
Transfer function	tansig (no linear function)
Performance function	MSE (mean square error)
Error after learning	0.001
Divide function	dividerand
Train epochs	1000

fore, an architecture with one hidden layer with five hidden neurons was considered in this study (Fig. 4). Table 3 provides all the parameters chosen for training the NN.

5.2. GA optimization of the proposed NN architecture

In this phase, an integrated structure based-GA was first developed. This structure was subsequently applied to optimize the connection weights and thresholds at each neuron of the proposed NN architecture. Before GA operators can be applied, the proposed NN architecture must be first encoded as a chromosome. A real encoding was chosen versus binary encoding. Real encoding is increasingly being recommended for optimizing complex problems in which the parameter space is continuous [63]. This type of encoding transforms the neural network in a chromosome (vector) represented by a real string (connection weights and bias) (Fig. 5(a)).

Then, an initial population of a predefined size composed of multiple chromosomes was generated. The best chromosomes are more likely to be chosen for reproduction based on a selection criterion, making them more likely to be selected for the next generation. The selection criterion is primarily based on the fitness of each chromosome. The evolving genetic operators were applied to these chromosome, as shown in Fig. 5(a).

Crossover, the first evolving operator, was applied simultaneously for crossing NN weights and thresholds (neurons) (Fig. 5 (b)). For each crossing of each of the different combinations of both chromosomes (called parents), weights and thresholds were randomly selected to generate two chromosomes (called “daughters”).

Mutation, the second evolving operator, randomly reversed the weight and threshold values of each daughter chromosome to generate good chromosomes (Fig. 5(c)).

Generating a new configuration of NN weights and thresholds is an iterative process, in which the bad solutions are eliminated based on the ‘MSE’ (mean squared error) function as fitness function. Each new NN network configuration was then driven with the back-propagation algorithm to adjust the weights and thresholds based on the MSE performance function (Eq. (4)). This function measures the “average” error, weighted according to the square of the difference between the forecast and the observation

ond phase is to optimize the proposed architecture by applying a GA. The third phase is dedicated to selecting and assessing the performance of the optimized NNGA hybrid model. The model was implemented and simulated using the neural networks and genetic algorithm toolbox functions in MATLAB R2014a [37].

5.1. Determination of NN parameters

Various factors may affect NN performance. They related, on one hand, to network topology and, on the other, to learning parameters. The parameters related to network topology include the number of inputs/outputs, hidden layers, and neurons in each hidden layer. Learning parameters mainly concern the choice of learning algorithm, performance function, the transfer function in hidden layers, the maximum error, and the number of learning cycles. In this phase, the number of hidden layers was chosen to make the system as simple as possible and thus avoid extending the learning time. The number of neurons in the hidden layer was changed to explore its effect on the NN performance. There-

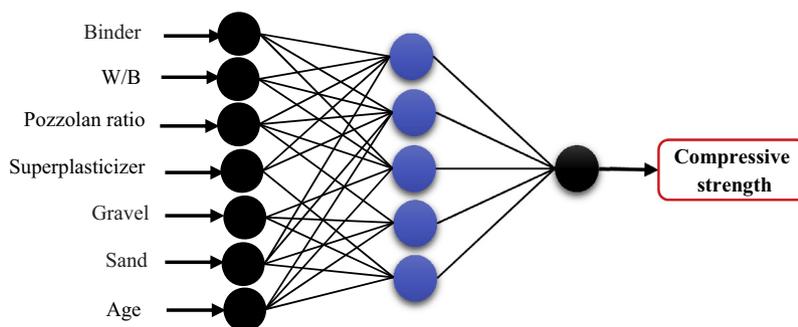
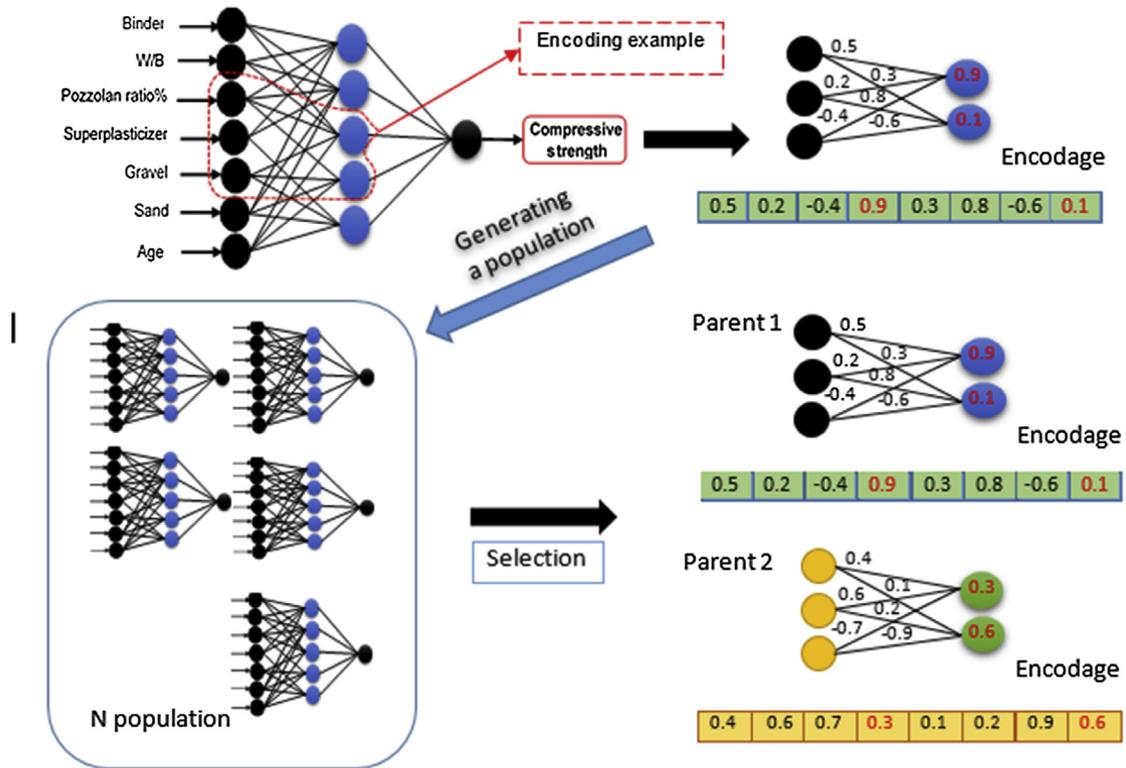
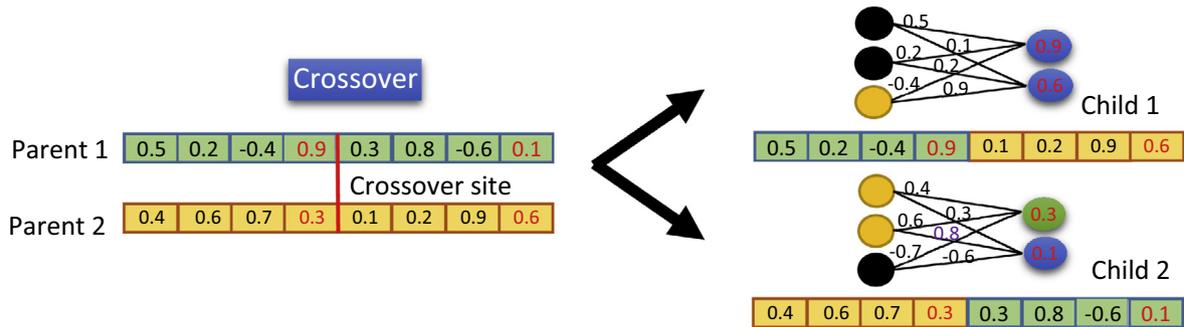


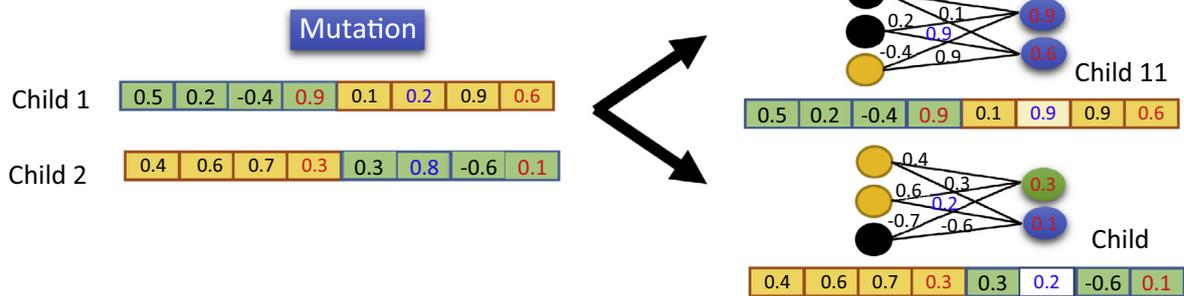
Fig. 4. Architecture of the proposed NN model.



(a) Encoding and selection



(b) Crossover



(c) Mutation

Fig. 5. Encoding scheme of NN architecture and GA operators (a) Encoding and selection, (b) Crossover, (c) Mutation.

Table 4
The values of parameters used in the genetic algorithm.

GA parameters	Values and nomination in MATLAB
Population size	50
Generation number	10
Mutation function	@mutationuniform
Crossover function	@crossoverheuristic
Selection function	@selectiontournament
Crossover fraction	0.2
Termination tolerance on fitness function value	TolFun

for understating the magnitudes of the errors. Table 4 provides all of the selected GA parameters.

$$MSE = \frac{1}{N} \sum_{k=1}^N ((t(k) - a(k))^2) \quad (4)$$

Where $t(k)$ is the target value of k^{th} pattern, $a(k)$ is the output value of k^{th} pattern, and N is the number of patterns.

5.3. Performance assessment of the hybrid NNGA model

This third phase is the decisive one. It represents the stopping criterion for the entire optimization process using the NNGA model. In this case, a sensitivity analysis was performed by comparing the hybrid NNGA model to an NN model using the same architecture. The comparison was made in terms of different performance indicators (or error), in particular, MSE (mean square error), RMSE (root mean square error), MAPE (mean absolute percentage error) and coefficient of determination (R^2). The value of the RMSE (Eq. (5)) describes the average size of errors in giving more weight to large errors, while the value of MAPE (Eq. (6))

can not apply for strictly positive values and allows a measure of the prediction accuracy of the predictive model. The correlation coefficient R^2 (Eq. (7)), however, measures the degree of association between observed and predicted values to justify the importance of the relationship under study. Generally, lower errors and higher R-squared values indicate good model performance. Table 5 shows the different values of these indicators in accordance with the learning of both developed models. According to this table, it is clear that the hybrid model NNGA is significantly more efficient and faster than the NN model.

$$RMSE = \sqrt{\left(\frac{1}{p}\right) * \sum_j (t_j - o_j)^2} \quad (5)$$

$$MAPE = \frac{1}{p} \sum_j \left(\left| \frac{o_j - t_j}{o_j} \right| * 100 \right) \quad (6)$$

$$R^2 = 1 - \left(\frac{\sum_j (t_j - o_j)^2}{\sum_j (o_j)^2} \right) \quad (7)$$

where t_j is the target value of j^{th} pattern, O_j is the output value of j^{th} pattern, and p is the number of patterns.

Due to the complex nature of the phenomenon, however, the self-validating criteria based on minimizing the error and maximizing the correlation was insufficient. Consequently, a large number of incorrect models with high R-squared and low error values were obtained, making choosing right model complicated. Hence, it was appropriate to compare the model results to those obtained by other models, on the one hand, and to those achieved by carrying out an experimental program in the laboratory, on the other.

Table 5
Performance comparison between the NN and the NNGA models.

Model	MSE	RMSE	MAPE	R			R^2 experimental	Iteration number
				Training	Validation	Test		
NN	12.01	3.46	2.64	0.976	0.978	0.979	0.85	922
NNGA	8.13	2.85	2.18	0.970	0.961	0.955	0.93	131

Table 6
Chemical composition of materials used.

Binder	SiO ₂	Al ₂ O ₃	Fe ₂ O ₃	CaO	MgO	K ₂ O	Na ₂ O	SO ₃	SSB (m ³ /kg)
Cement	22.07	6.41	4.16	63.83	0.21	–	–	1.49	310
Natural pozzolan	46.86	16.62	9.37	9.38	2.84	–	–	0.36	400

Table 7
Concrete mix design.

Designation	W/B Ratio	Natural Pozzolan (%)	Cement (kg/m ³)	Water (l)	Superplasticizer (%)	Coarse Aggregate (kg/m ³)	Fine Aggregate (kg/m ³)
B1NP0	0.6	0	350	210	0	1130	720
B1NP10		10	305	210	0	1130	720
B1NP20		20	280	210	0	1130	720
B1NP30		30	245	210	0	1130	720
B2NP0	0.5	0	400	200	1	1100	720
B2NP10		10	360	200	1.2	1100	720
B2NP20		20	320	200	1.5	1100	720
B2NP30		30	280	200	1.9	1100	720
B3NP0	0.4	0	450	180	1.8	1050	720
B3NP10		10	405	180	2.1	1050	720
B3NP20		20	360	180	2.5	1050	720
B3NP30		30	315	180	2.8	1050	720

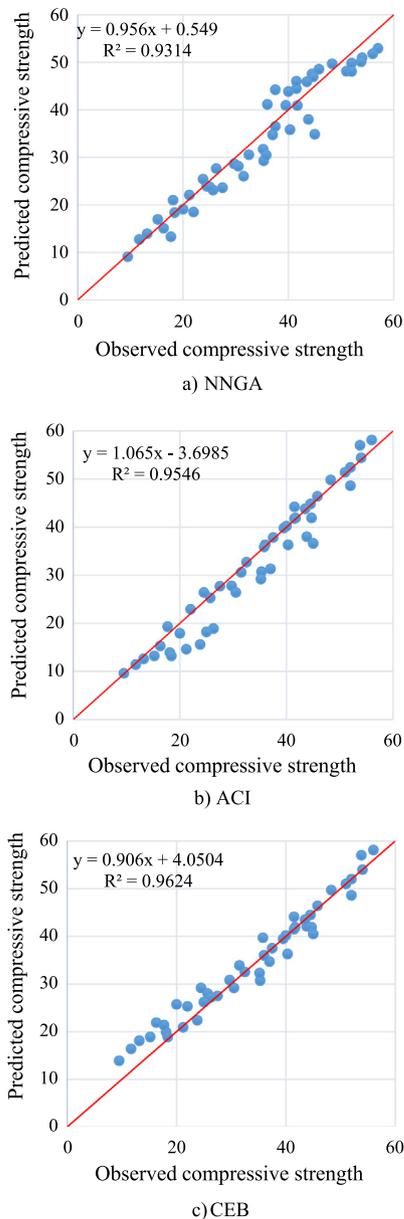


Fig. 6. Comparison of the observed and predicted compressive strength by models: (a) NNGA, (b) ACI, and (c) CEB.

These further validations focused on increasing the robustness and the reliability of the model.

6. Experimental validation and comprehensive comparison of the NNGA model

An experimental program was carried out to demonstrate the utility of the proposed method for improving the performance of the developed NNGA model. The completion of this program involved collecting the experimental results for compressive strength at 3, 7, 28, and 91 days from different concrete mixtures made with various water–binder ratios (0.4, 0.5, and 0.6). The study was focused mainly on two types of ordinary concrete in which 0%, 10%, 20%, and 30% of cements was replaced by natural pozzolan by weight.

An ordinary Portland cement (CEM I 42.5) was used with a natural pozzolan of volcanic origin extracted from the Bouhamdi deposit situated in southern Beni-Saf in Algeria and ground to a

Table 8
Relative errors of NNGA, ACI and CEB.

Models	NNGA	ACI	CEB
Relative error (%)	8.65	8.17	8.76

fineness of 400 m²/kg. Table 6 provides the chemical compositions and physical properties of the cement and natural pozzolan. Natural river sand with a fineness modulus of 2.64 and crushed gravel with a density of 2.64 were used as fine and coarse aggregate respectively. A naphthalene sulfonate-based superplasticizer was used to achieve the desired workability; its relative density at 25 °C is 1.21 and its solids content 40.5%.

Table 7 presents the proportions of the all the concrete mixtures used. The procedure used to batch the mixes complied with ASTM C 192 requirements. Cylindrical specimens of 100 × 200 mm were made from 12 concrete mixtures. After 24 h, the specimens were removed from their molds and kept in a fog room at 100% relative humidity and a temperature of 20 °C ± 3 °C until the day of testing. The compressive strengths were measured at 3, 7, 28, and 91 days according to ASTM C 93. Each measurement of compressive strength is the average of three cylinders.

To demonstrate the prediction ability of the proposed methodology, the results of these 12 mixtures were compared with those calculated using the developed model by introducing the same compositions of mixtures, on one hand, with those obtained from other existing models such as the ACI 209-08 [10] and the CEB-FIP 2010 [11] on the other. The equations used for predicting the compressive strength at any time based on the 28-day strength according to the ACI and CEB-FIP models are shown, respectively, as follow:

$$(f'_c)_t = \left(\frac{t}{\alpha + \beta t} \right) (f'_c)_{28} \quad (8)$$

where α in days and β are constants, t is the concrete age (days), $(f'_c)_{28}$ and $(f'_c)_t$ are the compressive strength concrete at 28 and t days, respectively. The constants α and β are functions of both the cement type used and curing employed. For this comparison, cement type I was used; specimens were moist cured for all new experimental data and the constants α and β become 4.0 and 0.85, respectively.

$$(f'_c)_t = \exp \left\{ s \left[1 - \left(\frac{28}{t} \right)^{0.5} \right] \right\} (f'_c)_{28} \quad (9)$$

where s is a coefficient that depends on the cement strength class, t is the concrete age (days), and $(f'_c)_{28}$ and $(f'_c)_t$ are the compressive strength concrete at 28 and t days, respectively. For a cement with a strength class of 32.5R, 42.5 and s become 0.25.

Fig. 6 presents the experimental compressive strengths versus compressive strengths predicted by the ACI, CEB-FIP, and NNGA models. This figure shows that there is a perfect correlation between the compressive strength obtained experimentally and that predicted by the developed model. Moreover, the NNGA model developed in this study for predicting the compressive strength of concrete with natural pozzolan yielded very satisfactory results with strong positive R^2 results of 0.93. These results are very similar and comparable to those obtained by the ACI and the CEB-FIP models with R^2 coefficients of 0.95 and 0.96, respectively.

Additionally, Table 8 summarizes the computed relative errors of each predictive model as expressed by Eq. (10).

$$E(\%) = \left| \left(\frac{O_{exp} - O_{bmod}}{O_{exp}} \right) \right| \times 100 \quad (10)$$

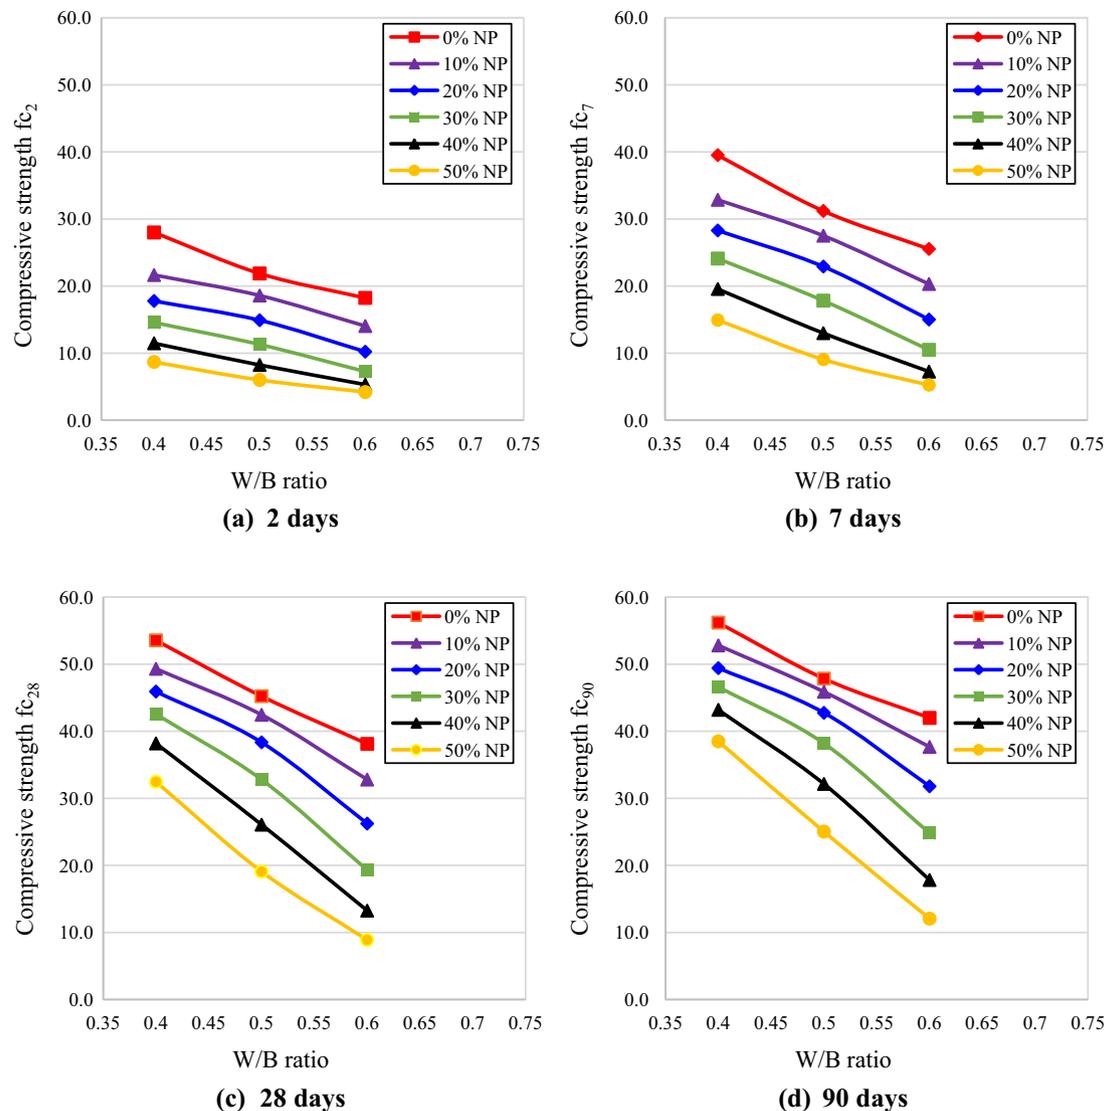


Fig. 7. Effect of W/B ratio on the compressive strength with age.

O_{exp} is the experiment output and O_{mod} is the output obtained by predictive models, including the NNGA, ACI, and CEB models. According to this table, using the proposed NNGA hybrid model can more accurately predict the compressive strength of concrete containing natural pozzolan compared with other codes, such as ACI and CEB-FIP because it takes into account more important mix proportions and especially the time evolution of compressive strength.

7. Parametric analysis based on the NNGA results

The NNGA model can be used to simulate the effect of some parameters on the compressive strength of concrete with natural pozzolan that depend mainly on the concrete mixture and concrete age. The analysis led to the simulation results shown in Figs. 7 and 8. In this analysis, one parameter was varied, while the others were kept constant. Functional relations were obtained between the compressive strength and its corresponding factors (binder content, percentage of cement replacement with a natural pozzolan, water–binder ratio, and curing age). The simulation results show the large effect of the cement replacement ratio with a natural pozzolan

on the compressive strength of the concrete mix, which was produced based on the data listed in Table 9. Conclusions drawn from these curves conform to some rules on concrete-mix proportioning well known in the concrete technology [64,65]. It has been also found that the compressive strength of the concrete with natural pozzolan can be improved either by increasing the binder volume and a reduction in water–binder ratio if using a superplasticizer. To some extent, these reasonable results indicate that the developed NNGA model performs well.

7.1. Effect of water to binder ratio

Fig. 7 shows the influence of the Water to Binder (W/B) ratio on the compressive strength of concretes containing different amounts of natural pozzolan (from 10% to 50%) at various ages (from 2 to 92 days). A similar trend was reported by other researcher, where it was found that the higher the W/B, the lower the compressive strength at different ages [64,65]. Reducing the W/B from 0.6 to 0.4 improved strength from the first day. After 28 days of curing, the improvement reached 40%, 50%, 75%, 120%, 190%, and 260% for natural pozzolan substitution rates of 0%,

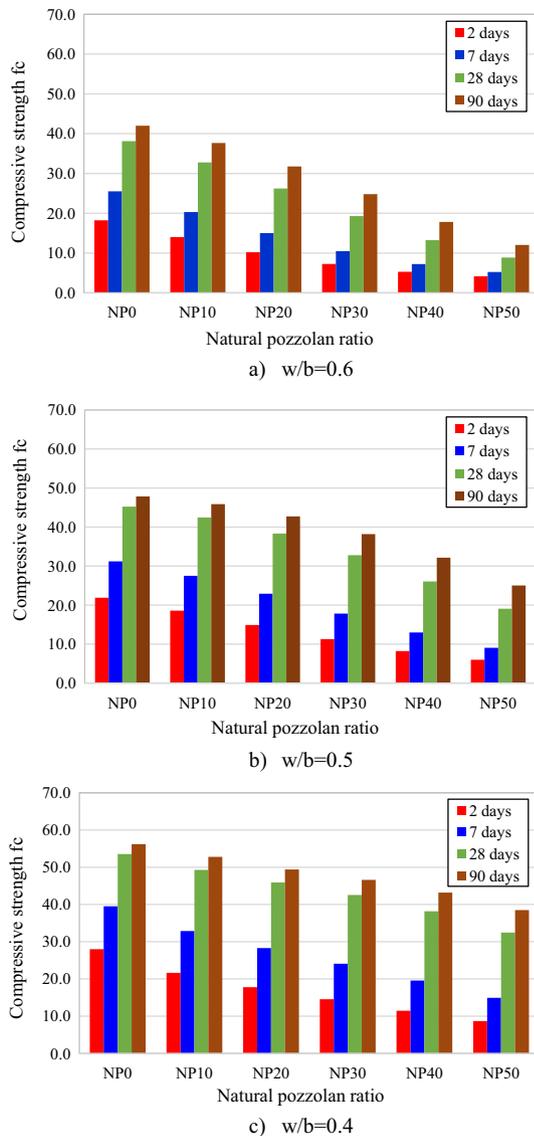


Fig. 8. Effect of age on the compressive strength at different w/b ratios $w/b = 0.6$, $w/b = 0.5$, $w/b = 0.4$.

10%, 20%, 30%, 40% and 50% respectively. At 90 days, the concrete with 10% of natural pozzolan reached a compressive strength similar to that of the control concrete at a W/B ratio of 0.5.

Table 9
Data analysis for parametric study.

W/B	Age (days)	Binder (kg/m^3)	Natural Pozzolan (%)	SP (%)	Gravel (kg/m^3)	Sand (kg/m^3)
0.6	2	350	0, 10, 20, 30, 40, 50	0	1200	700
	7	350	0, 10, 20, 30, 40, 50			
	28	350	0, 10, 20, 30, 40, 50			
	90	350	0, 10, 20, 30, 40, 50			
0.5	2	400	0, 10, 20, 30, 40, 50	1	1200	700
	7	400	0, 10, 20, 30, 40, 50			
	28	400	0, 10, 20, 30, 40, 50			
	90	400	0, 10, 20, 30, 40, 50			
0.4	2	450	0, 10, 20, 30, 40, 50	2	1200	700
	7	450	0, 10, 20, 30, 40, 50			
	28	450	0, 10, 20, 30, 40, 50			
	90	450	0, 10, 20, 30, 40, 50			

7.2. Influence of amount of natural pozzolan with age

The variation in compressive strength with cement replacement ratio with a natural pozzolan (NP) ranging from 10% to 50% at various ages and for different W/B ratios (0.4, 0.5, and 0.6) is given in Fig. 8. This figure shows the great effect of the cement replacement ratio with a natural pozzolan on the compressive strength of concrete at different ages. At any age, the compressive strength tends to decrease as the replacement ratio increases. Introducing a natural pozzolan does not produce an immediate improvement in compressive strength with respect to the control mix. Loss of strength at early ages, which was proportional to cement replacement ratio, was probably due to the dilution effect of the natural pozzolan and the slow nature of pozzolanic reaction. It should also be noted that the concrete mixes with natural pozzolan seem to develop compressive strength faster than the control mixes from 28 days for relatively high rates of natural pozzolan (40% or 50%).

The model show that at high volume natural pozzolan ratio, an acceptable compressive strength can be reached by reducing w/b ratio. For example, at a 40% replacement ratio, the concrete strength increased from 13 to 38 MPa at 28 days when changing the W/B ratio from 0.6 to 0.4.

8. NNGA model-based user interface development

Nowadays, concrete designers are focusing on developing concrete software that is more robust and user friendly, resulting in a wider applicability. Indeed, considerable effort has gone into ensuring that the system developed in this study is useful and practical. Moreover, for ease of use, a user-oriented visual interface has been implemented (Concrete Compressive Strength Simulator V.1 “CCSS”) using the Delphi programming language [38]. Fig. 9 shows the main user interface, which is simple and extremely easy to use. As shown in this figure, good computer software encourages the user to ask for and specify concrete requirements. First, a dropdown list facilitates selecting both types of concrete and additive. The concrete exposure conditions and the air-entraining agent to be used are then selected. After that, the NNGA code is executed by clicking the Next button.

Fig. 10 shows the second interface that allows the user to enter numeric values for testing age, water–binder ratio, amount of binder, and the ratio of cement replacement with a natural pozzolan, superplasticizer, and the amount of aggregates. Lastly, the concrete compressive strength is displayed directly by clicking the Predict button.



Fig. 9. CCSS main menu.

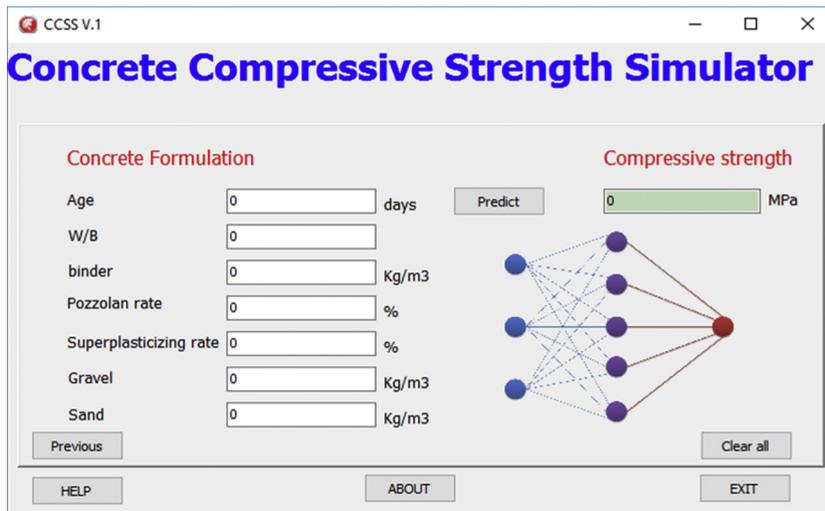


Fig. 10. NNGA interactive graphical user interface.

9. Conclusion

An NNGA hybrid model to predict the compressive strength of concretes containing a natural pozzolan and its evolution as a function of age has been developed based on the hybridization of neural-network (NN) techniques and genetic algorithms (GAs). A new advanced hybridization structure was first developed and then integrated into a neural network before learning the NN for optimizing its architecture in terms of weight connection and bias which are often randomly generated. This model has proven to be more efficient and faster in comparison with NNs. This was clearly shown by comparing the various model performance indicators—MSE, RMSE, MAPE, and determination coefficient R^2 , respectively—which were equal to 8.13, 2.85, 2.18, and 0.93 for the NNGA hybrid model and 12.01, 3.46, 2.62, and 0.85 for the NN model.

Due to the complex nature of the phenomenon, the self-validating criteria based on minimizing the error and maximizing the correlation was insufficient. Therefore, further validations focused on increasing the model's robustness and reliability. Hence, this model was first validated experimentally by conduct-

ing an experimental laboratory program and then compared to other models. The validation results clearly showed very satisfactory results with a very good coefficient R^2 of 0.93. These results are very similar and comparable with those obtained by the ACI 209-08 and CEB-FIP 2010 models with R^2 values equal to 0.95 and 0.96, respectively.

The NNGA model developed has also been used to simulate the effect of some parameters on the compressive strength of concrete containing natural pozzolan, which depends mainly on the concrete mixture and age. Functional relations were obtained in accordance with the rules on concrete-mix proportioning, which researchers have discovered and accepted. The compressive strength of the concrete was significantly affected by adding a natural pozzolan, and it can be improved either by increasing the binder volume or reducing the water-binder ratio. To some extent, these reasonable results indicate that the NNGA model developed performs well.

In addition, considerable effort has gone into ensuring that the system developed in this study is useful and practical. Moreover, for ease of use, a user-oriented visual interface has been implemented (Concrete Compressive Strength Simulator V.1).

References

- [1] F. De Larrard, T. Sedran, Le logiciel BétonlabPro 3, *Bull. Lab. Ponts Chaussées* 270–271 (2007) 75–85.
- [2] J.W. Bullard, P.E. Stutzman, L.M.O. Belloc, E.J. Garboczi, D.P. Bentz, *Virtual Cement and Concrete Testing Laboratory for Quality Testing and Sustainability of Concrete Spec Publ.*, vol. 266, 2009, pp. 27–36.
- [3] I.C. Yeh, Computer-aided design for optimum concrete mixtures, *Cem. Concr. Compos.* 29 (3) (2007) 93–202.
- [4] M.A. Sayed, Statistical modelling and prediction of compressive strength of concrete, *Concr. Res. Lett.* 3 (2) (2012) 451–458.
- [5] S. Alsanusi, L. Bentaher, Prediction of compressive strength of concrete from early age test result using design of experiments (RSM), *Int. J. Civ. Environ. Struct. Cons. Arch. Eng.* 9 (12) (2015) 1500–15004.
- [6] R.W. Nurse, Steam curing of concrete, *Mag. Concr. Res.* 1 (2) (1949) 79–88.
- [7] G. Chanvillard, L. D'Aloia, Prédiction de la résistance à la compression au jeune âge du béton: application de la méthode du temps équivalent, *Bull. Liaison LPC* 193 (1994) 39–51.
- [8] R. Féret, Sur la compacité des matériaux hydrauliques, *Annal. Ponts Chaussées* 4 (7) (1982) 5–164.
- [9] D.A. Abrams, Design of Concrete Mixtures, *Structural Materials Research Laboratory, Lewis Institute, Chicago*, 1918, pp. 1–7. Bulletin No. 1.
- [10] ACI Committee 209.2R-08, Guide for Modeling and Calculating Shrinkage and Creep in Hardened Concrete, American Concrete Institute, Farmington Hills, 2008.
- [11] Model Code 2010, The fib Model Code for Concrete Structures 2010, Comité Euro-International du Béton. *fib Bulletin N 65*, 2012, 350p.
- [12] F.A. Oluokun, Fly ash concrete mix design and water-cement ratio law, *ACI Mater. J.* 91 (4) (1994) 362–371.
- [13] K.G. Babu, G.S.N. Rao, Efficiency of fly ash in concrete with age, *Cem. Concr. Res.* 26 (3) (1996) 465–474.
- [14] G. Dreyfus, J.-M. Martinez, Réseaux de neurones, Eyrolles Coll Algorithmes Paris : Eyrolles, 2002.
- [15] L.A. Zadeh, G.J. Klir, B. Yuan, Fuzzy Logic, and Fuzzy Systems. Fuzzy Sets Selected Papers, World Scientific, 1996.
- [16] J.H. Holland, Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence, Reprint edition., A Bradford Book, Cambridge: Mass, 1992.
- [17] B. Boukhatem, S. Kenai, A. Tagnit-Hamou, M. Ghrici, Application of new information technology on concrete: an overview, *J. Civ. Eng. Manage.* 17 (2) (2011) 248–258.
- [18] T. Ji, T. Lin, X. Lin, A concrete mix proportion design algorithm based on artificial neural networks, *Cem. Concr. Res.* 36 (7) (2006) 1399–1408.
- [19] K.-B. Park, T. Noguchi, J. Plawsky, Modeling of hydration reactions using neural networks to predict the average properties of cement paste, *Cem. Concr. Res.* 35 (9) (2005) 1676–1684.
- [20] I.C. Yeh, Exploring concrete slump model using artificial neural networks, *J. Comput. Civ. Eng.* 20 (3) (2006) 217–221.
- [21] W. Dias, S. Pooliyadda, Neural networks for predicting properties of concretes with admixtures, *Constr. Build. Mater.* 15 (8) (2001) 371–379.
- [22] B. Boukhatem, S. Kenai, A. Tagnit Hamou, D. Ziou, M. Ghrici, A system for predicting concrete properties using neural networks (NN) with principal component analysis (PCA) Technique, *Comput. Concr.* 10 (6) (2012) 557–574.
- [23] A.B. Goktepe, G. Inan, K. Ramyar, A. Sezer, Estimation of sulfate expansion level of PC mortar using statistical and neural approaches, *Constr. Build. Mater.* 20 (7) (2006) 441–449.
- [24] E. Hewayde, M. Nehdi, E. Allouche, G. Nakhla, Neural network prediction of concrete degradation by sulphuric acid attack, *Struct. Infrastruct. Eng.* 3 (1) (2007) 17–27.
- [25] C.-M. Lin, T.-K. Chu, T.-P. Chang, Cement roller mill control by fuzzy logic controller, *J. Control Syst. Technol., Yuan-Ze Inst. Technol. Chung-Li Taiwan* 4 (2) (1996) 133–138.
- [26] S. Akkurt, G. Tayfur, S. Can, Fuzzy logic model for the prediction of cement compressive strength, *Cem. Concr. Res.* 34 (8) (2004) 1429–1433.
- [27] T. Uygunoglu, O. Unal, A new approach to determination of compressive strength of fly ash concrete using fuzzy logic, *J. Sci. Ind. Res.* 65 (11) (2006) 894–899.
- [28] M. Sandemir, Empirical modeling of splitting tensile strength from cylinder compressive strength of concrete by genetic programming, *Expert Syst. Appl.* 38 (11) (2011) 14257–14268.
- [29] P. Chopra, R.K. Sharma, M. Kumar, Prediction of compressive strength of concrete using artificial neural network and genetic programming, *Adv. Mater. Sci. Eng.* 2016 (2016) 1–10.
- [30] I. González-Taboada, B. González-Fonteboa, F. Martínez-Abella, J.L. Pérez-Ordóñez, Prediction of the mechanical properties of structural recycled concrete using multivariable regression and genetic programming, *Constr. Build. Mater.* 106 (2016) 480–499.
- [31] E. Ozbay, M. Gesoglu, E. Güneyisi, Empirical modeling of fresh and hardened properties of self-compacting concretes by genetic programming, *Constr. Build. Mater.* 22 (8) (2008) 1831–1840.
- [32] M. Sonebi, A. Cevik, Genetic programming based formulation for fresh and hardened properties of self-compacting concrete containing pulverised fuel ash, *Constr. Build. Mater.* 23 (7) (2009) 2614–2622.
- [33] V. Chandwani, V. Agrawal, R. Nagar, Modeling slump of ready mix concrete using genetic algorithms assisted training of artificial neural networks, *Expert Syst. Appl.* 42 (2) (2015) 885–893.
- [34] I.B. Topçu, M. Sandemir, Prediction of compressive strength of concrete containing fly ash using artificial neural networks and fuzzy logic, *Comput. Mater. Sci.* 41 (3) (2008) 305–311.
- [35] Z. Yuan, L.-N. Wang, X. Ji, Prediction of concrete compressive strength: Research on hybrid models genetic based algorithms and ANFIS, *Adv. Eng. Softw.* 67 (2014) 156–163.
- [36] M.J. McConnell, M.R. Lindberg, K.J. Brennand, J.C. Piper, T. Voet, C. Cowing-Zitron, S. Shumilina, R.S. Lasken, J.R. Vermeesch, I.M. Hall, F.H. Gage, Mosaic copy number variation in human neurons, *Science* 342 (6158) (2013) 632–637.
- [37] Neural Network and Genetic algorithms for user with MATLAB 8, The Math Works Inc, Prentice Hall, 2014.
- [38] DELPHI 10, Developer's Guide, Borland Software Corporation, USA, 2014, p. 1106.
- [39] D.E. Goldberg, Genetic Algorithms in Search, Optimization and Machine Learning, first ed., Addison-Wesley Longman Publishing Co Inc., Boston, MA, USA, 1989.
- [40] J.H. Holland, Adaptation in Natural and Artificial Systems, MIT Press, Cambridge, MA, USA, 1992.
- [41] S.N. Sivanandam, S.N. Deepa, Genetic algorithm optimization problems, in: Introduction to Genetic Algorithms, Springer, Berlin Heidelberg, 2008, pp. 165–209.
- [42] M. Gen, R. Cheng, Genetic Algorithms and Engineering Optimization, first ed., Wiley-Interscience, New York, 1999.
- [43] M.G. Sahab, A.F. Ashour, V.V. Toropov, A hybrid genetic algorithm for reinforced concrete flat slab buildings, *Comput. Struct.* 83 (8–9) (2005) 551–559.
- [44] M. Nehdi, T. Greenough, Modeling shear capacity of RC slender beams without stirrups using genetic algorithms, *Smart Struct. Syst.* 3 (1) (2007) 51–68.
- [45] C.H. Lim, Y.S. Yoon, J.H. Kim, Genetic algorithm in mix proportioning of high-performance concrete, *Cem. Concr. Res.* 34 (3) (2004) 409–420.
- [46] S. Gecynalda, da S. Gomes, T.B. Ludermir, Optimization of the weights and asymmetric activation function family of neural network for time series forecasting, *Expert Syst. Appl.* 40 (16) (2013) 6438–6446.
- [47] R. Gupta, M.A. Kewalramani, A. Goel, Prediction of concrete strength using neural-expert system, *J. Mater. Civ. Eng.* 18 (3) (2006) 462–466.
- [48] S. Haykin, Neural Networks: A Comprehensive Foundation, 1st ed., Prentice Hall PTR, Upper Saddle River, NJ, USA, 1994.
- [49] A.I. Galushkin, Neural Networks Theory, Springer-Verlag, Berlin and Heidelberg GmbH & Co. K, Berlin: New York, 2007.
- [50] Y. Chauvin, D.E. Rumelhart, Backpropagation: Theory, Architectures, and Applications, 1st ed., Psychology Press, Hillsdale, NJ, 1995.
- [51] A.A. Ramezani-pour, Durability of Mortars and Concretes Made With a Natural Pozzolan, ACI Special Publication, 131 Ontario. Canada, 1992, pp. 209–218.
- [52] M.J. Shannag, A. Yeginobali, Properties of pastes, mortars and concretes containing natural pozzolan, *Cem. Concr. Res.* 25 (3) (1995) 647–657.
- [53] R. Dhir, M. McCarthy, Concrete in the Service of Mankind: Appropriate Concrete Technology, CRC Press, 2006.
- [54] L. Turanli, B. Uzal, F. Bektas, Effect of large amounts of natural pozzolan addition on properties of blended cements, *Cem. Concr. Res.* 35 (6) (2005) 1106–1111.
- [55] B.Y. Pekmezci, S. Akyüz, Optimum usage of a natural pozzolan for the maximum compressive strength of concrete, *Cem. Concr. Res.* 34 (12) (2004) 2175–2179.
- [56] A. Tagnit-Hamou, N. Petrov, K. Luke, Properties of concrete containing diatomaceous earth, *ACI Mater. J.* 100 (1) (2003) 73–78.
- [57] K.M.A. Hossain, M. Lachemi, Development of volcanic ash concrete: strength, durability, and microstructural investigations, *ACI Mater. J.* (2006).
- [58] B. Uzal, L. Turanli, P.K. Mehta, High-volume natural pozzolan concrete for structural applications, *ACI Mater. J.* 104 (5) (2007) 535–538.
- [59] A. Naseer, A. Jabbar, A.N. Khan, Q. Ali, Z. Hussain, J. Mirza, Performance of Pakistani volcanic ashes in mortars and concrete, *Can. J. Civ. Eng.* 35 (12) (2008) 1435–1445.
- [60] N. Kaid, M. Cyr, S. Julien, H. Khelafi, Durability of concrete containing a natural pozzolan as defined by a performance-based approach, *Constr. Build. Mater.* 23 (12) (2009) 3457–3467.
- [61] B.J. Olawuyi, K.O. Olusola, Compressive strength of volcanic ash/ordinary portland cement laterized concrete, *Civ. Eng. Dimens.* 12 (1) (2010) 23–28.
- [62] S.-T. Yi, E.-I. Yang, J.-C. Choi, Effect of specimen sizes, specimen shapes, and placement directions on compressive strength of concrete, *Nucl. Eng. Des.* 236 (2) (2006) 115–127.
- [63] A. Alajmi, J. Wright, Selecting the most efficient genetic algorithm sets in solving building optimization problem, *Int. J. Sustain. Built. Environ.* 3 (1) (2014) 18–26.
- [64] A.M. Neville, Properties of Concrete, 4th ed., 1995 (Final Edition, Harlow, England).
- [65] P.K. Mehta, P.J.M. Monteiro, Concrete: Microstructure, Properties, and Materials, 3th ed., McGraw-Hill, 2005.