

الجمهورية الجزائرية الديمقراطية الشعبية

REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

وزارة التعليم العالي والبحث العلمي

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

جامعة أبي بكر بلقايد - تلمسان

Université Aboubakr Belkaïd - Tlemcen -
Faculté de TECHNOLOGIE



THESE

Présentée pour l'obtention du **grade** de **DOCTEUR**

En : Génie Civil

Spécialité : Géotechnique

Par : BOUROUIS Mohammed el Amin

Sujet

Contribution à l'étude du fluage des sols argileux par les outils de l'intelligence artificielle.

Soutenue publiquement, le 04/ 07/ 2021, devant le jury composé de :

ALLAL Mohamed Amine	Prof. Université de Tlemcen	Président
ZADJAOUI Abdeldjalil	Prof. Université de Tlemcen	Directeur de thèse
DJEDID Abdelkader	Prof. Université de Tlemcen	Co-Directeur de thèse
BOUROKBA MRABENT Souad Amel	MCA Université STOMB Oran	Examinatrice
AISSA MAMOUNE Sidi Mohammed	Prof. Université d'Ain Témouchent	Examineur

REMERCIEMENTS

Au terme de ce modeste travail, je voudrais exprimer ma profonde gratitude et présenter mes sincères remerciements à tous ceux qui ont contribué de près ou de loin à ce travail.

En premier lieu, je tiens à remercier mon directeur de thèse Monsieur **ZADJAOUI Abdeldjalil**, Professeur à l'Université de Tlemcen, pour sa modestie, sa patience, sa qualité pédagogique et humaine qui m'ont permis de mener ce travail dans les meilleures conditions. Il a fait preuve d'une grande disponibilité, m'a fourni un soutien constant et une aide précieuse. Il a toujours su me conseiller durant l'élaboration de ce travail de recherche, me faisant profiter ainsi de ses compétences théoriques et de son expérience.

Je tiens à adresser mes chaleureux remerciements à mon co-directeur de thèse Monsieur **DJEDID Abdelkader**, Professeur à l'Université de Tlemcen, de m'avoir guidé tout au long de ces années de thèse, pour avoir relu, corrigé et commenté très soigneusement ce manuscrit, je lui exprime toute ma gratitude et ma reconnaissance.

Je remercie aussi monsieur **ALLAL Mohamed Amine** professeur à l'université de Tlemcen, d'avoir accepté de présider le jury de ma thèse.

Mes remerciements s'adressent également aux membres du jury : Madame **BOUROKBA MRABENT Souad Amel** et **AISSA MAMOUNE Sidi Mohammed** pour leur lecture profonde, leur évaluation et d'avoir accepté d'examiner ce travail.

*En*fin mes chaleureux remerciements s'adressent à mes proches, mes amis, ma future femme et surtout mes parents et à tous ce qui m'ont soutenu de près ou de loin.

RÉSUMÉ

Contribution à l'étude du fluage des sols argileux par les outils de l'intelligence artificielle

L'estimation du tassement à long terme des sols fins a toujours posé des difficultés aux géotechniciens et ceci malgré l'amélioration des modèles numériques et des techniques expérimentales. Les difficultés proviennent essentiellement de la variabilité spatiale des propriétés du sol, des incertitudes liées à leurs déterminations et aussi à la simplicité des modèles utilisés. Le développement des techniques d'apprentissage, spécialement celles qui utilisent les méta-heuristiques et l'apprentissage profond « deep learning » ont entrouvert de grands espoirs pour les chercheurs. C'est dans ce cadre qu'a été inscrite cette thèse. Elle aborde le problème du fluage sous trois aspects.

Le premier axe concerne la prédiction du tassement à long terme par exploitation d'une base de données contenant des paramètres géotechniques facilement mesurables. A cet effet, deux méthodes ont été utilisées, la première basée sur une programmation génétique multi-gènes et la seconde sur une hybridation d'abord entre les réseaux neurones artificiels et les algorithmes d'optimisation, ensuite entre les algorithmes génétiques et les essais particuliers.

Le deuxième axe a trait à l'identification des paramètres de modèles constitutifs de sols par analyse inverse. La méthode d'identification utilisée, qui est adaptable à tout type de mesures, est basée sur un algorithme évolutionniste. Elle est présentée dans cette thèse avec ses avantages mais aussi ses limites d'utilisation.

Le troisième axe est relatif au développement de modèles capables de prédire le tassement à long terme. Deux approches ont été utilisées, la première par combinaison entre les modèles mathématiques dits multi-termes. La seconde approche a consisté en l'utilisation de l'apprentissage profond de type long short-term memory (LSTM) et convolution neural network (CNN) qui sont capables d'apprendre des relations non linéaires et complexes.

Les résultats obtenus montrent les avantages que peuvent présenter de telles méthodes que ça soit pour la prédiction du tassement à long terme mais aussi dans la détermination des paramètres de modèles constitutifs de sols. Les difficultés rencontrées et les limites de cette étude sont aussi exposées.

Mots-clés : Fluage, compression secondaire, programmation génétique, optimisation, réseaux de neurones, essai particulier, apprentissage profond.

SUMMARY

Contribution to the study of creep of clay soils using artificial intelligence tools

Estimating long-term settlement of fine soils has always been a challenge for geotechnicians, despite improvements in numerical models and experimental techniques. The difficulties stem essentially from the spatial variability of soil properties, the uncertainties related to their determination and also the simplicity of the models used. The development of learning techniques, especially those using meta-heuristics and deep learning, have raised great hopes for researchers. It is within this framework that this thesis has been written. It approaches the problem of creep under three aspects.

The first axis concerns the prediction of long-term settlement by using a database containing easily measurable geotechnical parameters. For this purpose, two methods were used, the first based on multi-gene genetic programming and the second on a hybridization first between artificial neural networks and optimization algorithms, then between genetic algorithms and particle swarms.

The second axis relates to the identification of the parameters of soil constitutive models by inverse analysis. The identification method used, which is adaptable to any type of measurements, is based on an evolutionary algorithm. It is presented in this thesis with its advantages but also its limits of use.

The third axis relates to the development of models capable of predicting long-term settlement. Two approaches have been used, the first one by combining so-called multi-term mathematical models. The second approach consisted in the use of long short-term memory (LSTM) and convolution neural network (CNN) deep learning which are capable of learning complex non-linear relationships.

The results obtained show the advantages that such methods can offer both for the prediction of long-term settlement and for the determination of parameters of soil constitutive models. The difficulties encountered and the limitations of this study are also exposed.

Key-words: Creep, secondary compression, genetic programming, optimization, neural networks, particle swarm, deep learning.

ملخص

المساهمة في دراسة التشوه البطيء للأتربة الطينية باستخدام أدوات الذكاء الاصطناعي

على الرغم من تطور التي شهدته النماذج الرقمية وتقنيات التجارب الا انه مازال يفرض تشوه التربة على المدى الطويل صعوبات كبيرة على الجيوتقنيين. هاته الصعوبات تأتي بالأساس من التغير المكاني لخصائص التربة، من الارتبايات اثناء استخراجها وأيضاً من بساطة النماذج المستعملة. لقد فتح تطوير تقنيات التعلم، خاصة تلك التي تستخدم الاستدلال الفوقي والتعلم العميق، أملاً كبيراً لدى الباحثين. في هذا السياق، العمل المقدم في هذه الأطروحة يعالج مشكلة التشوه البطيء من ثلاثة جوانب. يتعلق المحور الأول بالتنبؤ للانضغاط طويل الأمد باستخدام قاعدة بيانات تحتوي على خصائص جيوتقنية سهلة القياس. ولهذه الغاية، تم استخدام طريقتين، الأولى تعتمد على البرمجة الجينية متعددة الجينات والثانية على التهجين أولاً بين الشبكات العصبية لاصطناعية وخوارزميات التحسين، ثم بين الخوارزميات الجينية وأسراب الجسيمات. اما المحور الثاني يتعلق الامر باستخراج خصائص التربة من النماذج التكوينية عن طريق التحليل العكسي. الطريقة المستخدمة تعتمد على خوارزمية تطويرية قابلة للتكيف مع أي نوع من القياس، في هذه الدراسة سيتم تقديم مزاياها وحدود استخدامها. المحور الثالث يتعلق بتطوير النماذج القادرة على توقع التشوه طويل الأمد. في هذه الدراسة تم استخدام نهجين، الأول من خلال الجمع بين نماذج رياضية متعددة الاقطاب. والنهج الثاني يعتمد على التعلم العميق ويخص الذاكرة طويلة المدى والشبكة العصبونية الانتقافية القادران على تعلم العلاقات غير الخطية والمعقدة. تظهر النتائج المتحصل عليها سواء عن طريق تنبؤ مقدار تشوه التربة على المدى الطويل او خائص التربة صعوبات ومجال استخدامها المستخرجة إيجابيات النماذج المقترحة. كما نتطرق أيضاً في هذه الدراسة الى

الكلمات المفتاحية : التشوه البطيء، الضغط الثانوي ، البرمجة الجينية ، التحسين ، الشبكات ، العصبية ، سرب الجسيمات ، التعلم العميق

TABLE DES MATIERES

REMERCIEMENT	I
RÉSUMÉ	II
SUMMARY	III
ملخص	IV
TABLE DES MATIERES	V
LISTE DES FIGURES	X
LISTE DES TABLEAUX	XVI
INTRODUCTION GÉNÉRALE	1
CHAPITRE 1	
ETAT DE CONNAISSANCES SUR LE FLUAGE DES SOLS ARGILEUX	4
1 Introduction	4
2 Revue de littérature.....	4
3 Considérations théoriques.....	6
3.1 Niveaux de déformation	6
3.1.1 Niveau moléculaire de la déformation du sol.....	6
3.1.2 Le niveau des particules de la déformation du sol.....	7
3.1.3 Le niveau structural de la déformation du sol	7
3.1.4 La déformation du sol au niveau des agrégats.....	8
3.2 Le fluage du sol	8
3.2.1 Les catégories de la déformation due au fluage	9
3.2.2 Effets du temps.....	10
3.2.3 L'effet de niveau de contrainte.....	10
3.3 Théories du fluage	11
3.3.1 Compression Secondaire vs Consolidation Secondaire.....	11
3.3.2 La Théorie de Buisman	11
3.3.3 La Théorie de Koppejan	12
3.3.4 La Théorie de Mesri	12
3.3.5 La Théorie de Bjerrum	13
3.3.6 Hypothèses A et B.....	13
3.4 Modèles analogiques de base	13
3.4.1 Modèle de Newton	14
3.4.2 Modèle de Maxwell.....	14
3.4.3 Modèle de Kelvin	14
3.4.4 Modèle de Burger.....	15
3.4.5 Concept de Bingham	15
3.4.6 Modèle CVISC	15
4 Composantes du tassement.....	16
4.1 Tassement instantané.....	17

4.2	Tassement primaire	17
4.3	Le tassement secondaire	18
4.4	Caractéristiques de consolidation et de fluage	19
4.4.1	Caractéristiques de consolidation	19
4.4.2	Caractéristiques du fluage	21
4.5	Les différentes méthodes d'estimation des tassements	24
4.5.1	Méthode Asaoka.....	24
4.5.2	Méthode de Recordon	24
4.5.3	Méthode d'Al-Shamrani	25
4.5.4	Modèles mathématiques	26
5	Conclusion.....	27

CHAPITRE 2.....
L'ANALYSE DIRECTE ET INVERSE DANS LE CALCUL GEOTECHNIQUE 28

1	Introduction	28
2	Principaux types de lois de comportement	28
2.1	Comportement élastique linéaire.....	28
2.2	Comportement élastoplastique	28
2.2.1	Comportement élastique linéaire parfaitement plastique	29
2.2.2	Comportement élastoplastique avec écrouissage	30
2.3	Comportement élastique viscoplastique	31
3	Modèles et surfaces de charges adaptées aux sols fins	31
3.1	Modèles Cam-clay et Cam-clay modifié pour l'argile reconstituée.....	31
3.2	Modèles pour les argiles naturelles	32
3.3	Modèle de Larsson	34
3.4	Modèle Mélanie.....	35
3.4.1	Mélanie sans fluage.....	35
3.4.2	Mélanie avec fluage.....	36
3.5	Modèle Anpetal	37
3.6	Modèle S-CLAY1S	38
3.7	Modèle de Sekiguchi-Ohta.....	39
4	Modèles numériques.....	39
5	Programmes de calculs	43
5.1	CONDES	43
5.2	Mathematica (Wolfram, 1999).....	44
5.3	iConsol.js.....	44
5.4	CONMULT	45
5.5	CESAR-LCPC.....	46
5.6	PLAXIS.....	46
6	Analyse inverse.....	47
6.1	Analyse inverse en géotechnique	47
6.2	Résolution des problèmes inverses.....	49

6.2.1	Méthode analytique inverse.....	49
6.2.2	Analyse inverse par méthode numérique directe.....	49
6.3	Procédure de l'analyse inverse par méthode numérique directe	50
6.4	Algorithmes d'optimisation.....	51
6.4.1	Méthodes énumératives	51
6.4.2	Méthodes déterministes	51
6.4.3	Méthodes stochastiques	52
7	Conclusion.....	53

CHAPITRE 3.....

APPLICATION DE L'INTELLIGENCE ARTIFICIELLE EN GEOTECHNIQUE 54

1	Introduction	54
2	Traitement statistique et analyse de données	54
2.1	Collecte des données	54
2.2	Traitement statistique des données.....	54
2.2.1	Analyse en composantes principales.....	55
3	Méthodes statistiques de régression.....	55
3.1	Régression linéaire simple.....	55
3.2	Régression linéaire multiple	56
3.3	Régression non linéaire	56
3.4	Régression non-linéaire multiple.....	56
4	L'intelligence artificielle et ses applications dans la géotechnique.....	57
4.1	Réseaux neurones artificiels	57
4.1.1	Eléments de base	58
4.1.2	Modèle de fonctionnement	58
4.1.3	Architectures des réseaux	58
4.1.4	Apprentissage des réseaux neurones	60
4.1.5	Modèles des réseaux de neurones.....	61
4.1.6	Domaine d'application	63
4.2	Méthodes d'optimisation.....	63
4.2.1	Problème d'optimisation	64
4.2.2	Classification des méthodes de résolution des problèmes	64
4.3	Les approches méta-heuristiques pour l'optimisation mono-objectif	65
4.4	Méta-heuristiques à solution unique.....	66
4.4.1	Méthode de descente	67
4.4.2	Recuit simulé.....	67
4.4.3	Recherche tabou	67
4.5	Méta-heuristiques à base de population de solutions	68
4.5.1	Algorithmes évolutionnaires	68
4.5.2	Algorithmes d'intelligence en essaim	70
4.6	Hybridation des méta-heuristiques	72

4.6.1	Classification hiérarchique	72
4.6.2	Application des méta-heuristiques dans la géotechnique	73
5	Apprentissage profond.....	74
5.1	Quelques algorithmes de Deep Learning	75
5.2	Les réseaux de neurones convolutionnels (CNN)	75
5.2.1	Le fonctionnement des réseaux de neurones convolutifs	75
5.2.2	Architecture de réseau de neurone convolutif	76
5.3	Réseau de neurones à mémoire court- long terme (LSTM) :	77
5.3.1	Fonctionnement des réseaux de neurones LSTM.....	77
6	Indicateurs de l'analyse techniques	78
6.1	Rôle des indicateurs technique dans les études géotechniques	78
6.2	Indicateurs techniques de direction	79
6.2.1	Moyenne mobile (SMA).....	79
6.2.2	Indicateurs technique d'oscillations	79
7	Conclusion.....	80

CHAPITRE 4.....
LA PREDICTION DES PROPRIETES GEOTECHNIQUES DES SOLS..... 82

1	Introduction	82
2	Estimation des paramètres de compressibilité.....	82
2.1	Prédiction de l'indice de compression C_c	82
2.1.1	Description et traitement de la base de données.....	82
2.1.2	Régression simple.....	83
2.1.3	Prédiction de l'indice de compression par le RNA	84
2.1.4	Prédiction de l'indice de compression par le NG.....	86
2.2	Prédiction de l'indice de compression secondaire C_α	90
2.2.1	Description et traitement de la base de données.....	91
2.2.2	Régression simple.....	92
2.2.3	Prédiction de l'indice de compression par NN-PSO.....	93
2.2.4	Prédiction de l'indice de compression par MGGP.....	95
3	Identification des paramètres par l'analyse inverse	98
3.1	Procédure d'analyse inverse	99
3.2	Etude paramétrique.....	100
3.3	Optimisation par l'algorithme génétique	103
3.3.1	Essai œdométrique Monocouche (MC).....	103
3.3.2	Essai œdométrique double couche (DC)	104
3.3.3	Remblai B de Cubzac les Ponts.....	106
4	Conclusion.....	111

CHAPITRE 5.....
PREDICTION DU TASSEMENT A LONG TERME.....	111
1 Introduction	113
2 Présentation du site et caractéristiques des sols.....	114
2.1 L'aéroport international du Kansai	114
2.1.1 Observations sur le comportement du remblai	115
2.1.2 Propriétés physico-chimiques et hydriques du sol	116
3 Prévision des tassements à long terme.....	116
3.1 Prévision du tassement par la méthode d'Asaoka	117
3.1.1 Résultats et validation de l'approche.....	117
3.2 Prévision du tassement par MTM.....	118
3.2.1 Mise en application de la MTM	118
3.2.2 Résultat et discussions	119
3.3 Prévision du tassement par MGGP.....	121
3.3.1 Mise en équation et programmation de l'MGGP	121
3.3.2 Résultats et validation du modèle.....	122
3.4 Prévision du tassement par l'apprentissage profond	128
3.4.1 Traitement de données.....	129
3.4.2 Prévision du tassement par réseau LSTM	129
3.4.3 Prévision du tassement par un réseau CNN.....	134
3.5 La comparaison entre les approches développées MGGP, LSTM et CNN.....	138
4 Prévision de la pression interstitielle	140
4.1 Prévision de la pression interstitielle par MGGP	140
4.1.1 Résultats et validation du modèle.....	140
4.2 Prévision de la pression interstitielle par l'apprentissage profond	146
4.2.1 Prévision de la pression interstitielle par un réseau LSTM.....	146
4.2.2 Prévision de la pression interstitielle par un réseau CNN	150
4.3 La comparaison entre les approches développées MGGP, LSTM et CNN.....	154
5 Conclusion.....	155
CONCLUSION GÉNÉRALE	156
PERSPECTIVES.....	159
RÉFÉRENCES BIBLIOGRAPHIQUES	160

LISTE DES FIGURES

CHAPITRE I

Figure 1.1 Niveau moléculaire de la déformation (Poppe et al., 2018).....	7
Figure 1.2 Niveau de la déformation des particules du sol (Herling et Breu, 2014)	7
Figure 1.3 Niveau structural de la déformation du sol.	8
Figure 1.4 Histoire géologique et compressibilité des argiles naturelles (Bjerrum, 1967).	10
Figure 1.5 Courbe d'état limite d'une argile naturelle (Bjerrum, 1967).	10
Figure 1.6 Le concept de compression primaire et secondaire (Bjerrum, 1967) adoptée par Bartholomeeusen (2003).	13
Figure 1.7 Présentation graphique de l'hypothèse A et B.	13
Figure 1.8 Représentation du modèle analogique de Newton en cisaillement simple	14
Figure 1.9 Représentation analogique du modèle de Maxwell en cisaillement simple.....	14
Figure 1.10 Représentation du modèle analogique de Kelvin en cisaillement simple	15
Figure 1.11 Représentation du modèle analogique de Burger en compression simple	15
Figure 1.12 Modèle analogique de Bingham en cisaillement simple.....	16
Figure 1.13 Modèle dérivé CVISC en compression simple.	16
Figure 1.14 Phénomène de la consolidation primaire.	18
Figure 1.15 Courbe de la consolidation primaire.	18
Figure 1.16 Phases d'évolution de fluage.	19
Figure 1.17 Courbe de la compressibilité.....	19
Figure 1.18 Méthode de Casagrande (1936)	20
Figure 1.19 Discrétisation de la courbe de consolidation.....	24
Figure 1.20 Construction d'Asaoka.....	24
Figure 1.21 Influence des coefficients B et C sur la solution de Recordon.....	25
Figure 1.22 Application de la méthode d'Al-Shamrani.	25

CHAPITRE II

Figure 2.1 Loi de comportement élastique linéaire	28
Figure 2.2 Loi de comportement élastique linéaire parfaitement plastique de Mohr-Coulomb.....	29
Figure 2.3 Capacité des lois à représenter l'évolution du module avec la déformation.....	30
Figure 2.4 Domaines de comportement de la loi élasto-viscoplastique.	31
Figure 2.5 Modèles Cam-Clay original et Cam-Clay modifié	32
Figure 2.6 Méthode de détermination de la surface de charge.	33
Figure 2.7 Surfaces de charge de différentes argiles naturelles Mestat (1993).	33
Figure 2.8 Surfaces de charge de l'argile de St-Alban Leroueil and Tavenas (1977).	34
Figure 2.9 Modèle de Larsson appliqué sur l'argile de Drammen (Larsson, 1977).	34
Figure 2.10 Courbe d'état limite des argiles molles naturelles.	35

Figure 2.11 Surface d'état limite des argiles naturelles.	35
Figure 2.12 Les courbes isotropes de MELANIE (Lépidas 1990).....	36
Figure 2.13 Validation du modèle Anpétal sur différentes argiles (Newson (1997))......	38
Figure 2.14 Surface de charge du modèle S-CLAY1S et l'argile de POKO (Koskinen, et al., 2002b). 39	
Figure 2.15 Schéma de principe d'une analyse directe.	47
Figure 2.16 Schéma d'une méthode analytique inverse.	50
Figure 2.17 Schéma d'une analyse inverse par méthode numérique directe.....	50
Figure 2.18 Principe d'identification par méthode numérique directe.	50
Figure 2.19 Représentation de la fonction erreur sur l'espace de recherche (x_1, x_2).....	51
Figure 2.20 Représentation de la fonction erreur sur l'espace de recherche (x_1, x_2).....	51
Figure 2.21 Exploration de l'espace de recherche	52

CHAPITRE III

Figure 3.1 Analyse factorielle.	55
Figure 3.2 La cellule nerveuse et ses composantes.	58
Figure 3.3 La cellule nerveuse et ces composantes.	58
Figure 3.4 Structure d'un réseau monocouche.	59
Figure 3.5 Structure d'un réseau multicouche.....	59
Figure 3.6 Réseau à connexions locales.	59
Figure 3.7 Réseau à connexions récurrentes.	60
Figure 3.8 Réseau à connexions complète.	60
Figure 3.9 Principe d'apprentissage supervisé.	61
Figure 3.10 Principe d'apprentissage non supervisé.	61
Figure 3.11 Réseau à connexions complètes.....	62
Figure 3.12 Réseau à base de fonction radiale.	62
Figure 3.13 Structure cartes de Kohonen.	62
Figure 3.14 Différence entre un optimum global et des optima locaux.	64
Figure 3.15 Classification des méthodes d'optimisation (Dréo et al., 2003).	65
Figure 3.16 Classification des méta-heuristiques.....	66
Figure 3.17 Terminologie de l'algorithme génétique.....	68
Figure 3.18 Processus de sélection.....	69
Figure 3.19 Le processus de croisement.....	69
Figure 3.20 Processus de mutation.....	69
Figure 3.21 Schéma d'un arbre syntaxique.	70
Figure 3.22 L'organigramme d'un algorithme évolutionnaire.	70
Figure 3.23 Système d'action des colonies de fourmis.....	71
Figure 3.24 Principe du déplacement d'une particule.....	72
Figure 3.25 Structure typique d'un réseau neuronal convolutif.....	76
Figure 3.26 L'opération de convolution sur la hauteur et la largeur d'une image.....	76
Figure 3.27 L'opération dans la couche max-pooling.	77
Figure 3.28 Bloc du réseau de neurone Long Short Term Memory (LSTM).....	77

Figure 3.29 Moyenne mobile arithmétique des cours de clôture (Williams, 1998).....	79
Figure 3.30 Calcul de la vitesse d'évolution par l'indicateur Momentum (Williams 1998).....	80

CHAPITRE IV

Figure 4.1 Régression simple pour le paramètre e_0	83
Figure 4.2 Régression simple pour le paramètre w_n	83
Figure 4.3 Régression simple pour le paramètre G_s	84
Figure 4.4 Régression simple pour le paramètre LL	84
Figure 4.5 Régression simple pour le paramètre LP	84
Figure 4.6 Comparaison entre les valeurs mesurés et prédit par RNA1.....	85
Figure 4.7 Comparaison entre les valeurs mesurés et prédit par RNA2.....	85
Figure 4.8 Comparaison entre les valeurs mesurés et prédit par RNA3.....	85
Figure 4.9 Comparaison entre les valeurs mesurés et prédit par RNA4.....	85
Figure 4.10 Comparaison entre les valeurs mesurés et prédit par RNA5.....	86
Figure 4.11 Comparaison entre les valeurs mesurés et prédit par NG1.....	88
Figure 4.12 Comparaison entre les valeurs mesurés et prédit par NG2.....	88
Figure 4.13 Comparaison entre les valeurs mesurés et prédit par NG3.....	88
Figure 4.14 Comparaison entre les valeurs mesurés et prédit par NG4.....	88
Figure 4.15 Comparaison entre les valeurs mesurés et prédit par NG5.....	88
Figure 4.16 Comparaison entre le modèle RNA1 et NG1.....	89
Figure 4.17 Comparaison entre le modèle RNA2 et NG2.....	89
Figure 4.18 Comparaison entre le modèle RNA3 et NG3.....	89
Figure 4.19 Comparaison entre le modèle RNA4 et NG4.....	89
Figure 4.20 Comparaison entre le modèle RNA5 et NG5.....	90
Figure 4.21 Localisation des zones d'échantillonnage.....	91
Figure 4.22 Régression simple pour le paramètre w_n	92
Figure 4.23 Régression simple pour le paramètre e_0	92
Figure 4.24 Régression simple pour le paramètre σ_v	92
Figure 4.25 Identification du coefficient de consolidation secondaire.....	93
Figure 4.26 les arbres syntaxiques du gène 1, 2 et 3.....	96
Figure 4.27 les arbres syntaxiques du gène 4, 5 et 6.....	96
Figure 4.28 Visualisation globale de l'évolution de C_α en fonction e_0 et σ_v	97
Figure 4.29 Visualisation globale de l'évolution de C_α en fonction e_0 et w_n	97
Figure 4.30 Principe d'identification par méthode numérique directe.....	99
Figure 4.31 Schéma de principe d'optimisation par algorithme génétique.....	100
Figure 4.32 Variation du tassement en fonction λ^*	101
Figure 4.33 Variation du tassement en fonction κ^*	101
Figure 4.34 Variation du tassement en fonction μ^*	101
Figure 4.35 Variation du tassement en fonction C	101
Figure 4.36 Variation du tassement en fonction ϕ	101
Figure 4.37 Variation du tassement en fonction kh, kv	101

Figure 4.38 Plages de déplacement obtenu par la variation paramétrique.	102
Figure 4.39 Comparaison entre le tassement observé et simulé avant identification.	103
Figure 4.40 Comparaison entre le tassement observé et simulé après identification.	104
Figure 4.41 Géométrie et conditions aux limites du modèle.	105
Figure 4.42 Comparaison entre le tassement observé et simulé avant identification.	105
Figure 4.43 Comparaison entre le tassement observé et simulé après l'identification.	106
Figure 4.44 Maillage et conditions aux limites.	107
Figure 4.45 Calendrier de construction du remblai B (Michali, 1994).	108
Figure 4.46 Comparaison entre le tassement observé et simulé avant identification.	109
Figure 4.47 Évolution de la moyenne de F_{err} sur chaque génération.	109
Figure 4.48 Population initial.	110
Figure 4.49 Première génération.	110
Figure 4.50 Deuxième génération.	110
Figure 4.51 Troisième génération.	110
Figure 4.52 Quatrième génération.	111
Figure 4.53 Dixième à la dernière génération.	111
Figure 4.54 Comparaison entre le tassement observé et simulé après identification.	111

CHAPITRE V

Figure 5.1 Profil géologique d'Osaka (Mesri et al. 2015).	114
Figure 5.2 Profil sédimentaire sous-marin du site de Kansai (Mesri et al. 2015)	114
Figure 5.3 Schéma du tassomètre magnétique (Furudoï, 2010).	115
Figure 5.4 Tassement mesuré de la couche Ma12 de l'île I (Mesri et al. 2015).	115
Figure 5.5 Tassement mesuré de la couche Ma13 de l'île II (Mesri et al. 2015)	115
Figure 5.6 Pression interstitielle mesurée de la couche Ma12 de l'île I (Mimura et Jeon, 2013)	115
Figure 5.7 Pression interstitielle mesurée de la couche Ma13 de l'île II (Mesri et al. 2015)	115
Figure 5.8 Construction d'Asaoka avec un pas de temps égal à 100 jours de la couche Ma12.	117
Figure 5.9 Le tassement estimé par la méthode d'Asaoka de la couche Ma12.	117
Figure 5.10 Construction d'Asaoka avec un pas de temps égal à 100 jours de la couche Ma13.	118
Figure 5.11 Le tassement estimé par la méthode Asaoka de la couche Ma13.	118
Figure 5.12 Organigramme du programme développé.	118
Figure 5.13 Tassement mesuré et prédit par la méthode MTM-AG de la couche Ma12.	120
Figure 5.14 Tassement mesuré et prédit par la méthode MTM-PSO de la couche Ma12.	120
Figure 5.15 Tassement mesuré et prédit par la méthode MTM-AG de la couche Ma13.	121
Figure 5.16 Tassement mesuré et prédit par la méthode MTM-PSO de la couche Ma13.	121
Figure 5.17 Fonctionnement de l'algorithme MGGP.	122
Figure 5.18 Performances du modèle avec une seule variable (Ma12).	123
Figure 5.19 Tassement observé et prédit par le model MGGP-1input (Ma12).	123
Figure 5.20 Performances du modèle avec deux variables (Ma12).	124
Figure 5.21 Tassement observé et prédit par le modèle MGGP- 2 input (Ma12).	124
Figure 5.22 Les performances du model avec sept variables d'entrée (Ma12).	125

Figure 5.23 Tassement observé et prédit par le modèle MGGP- 7 input (Ma12).	125
Figure 5.24 Performances du modèle avec une seule variable (Ma13).	126
Figure 5.25 Tassement observé et prédit par le modèle MGGP- 1 input (Ma13).	126
Figure 5.26 Performances du modèle avec deux variables (Ma13).	127
Figure 5.27 Tassement observé et prédit par le modèle MGGP- 2 input (Ma13).	127
Figure 5.28 Performances du modèle avec 7 variables. (Ma13).	128
Figure 5.29 Tassement observé et prédit par le modèle MGGP- 7 input (Ma13).	128
Figure 5.30 Jeu de données adopté pour les modèles LSTM et CNN.	129
Figure 5.31 Tassement observé et prédit par le modèle LSTM- 1 input (Ma12).	130
Figure 5.32 Performances du modèle LSTM- 1 input (Ma12).	130
Figure 5.33 Tassement observé et prédit par le modèle LSTM-2 input (Ma12).	131
Figure 5.34 Performances du modèle LSTM-2 input (Ma12).	131
Figure 5.35 Tassement observé et prédit par le modèle LSTM- 7 input (Ma12).	131
Figure 5.36 Performances du modèle LSTM- 7 input (Ma12).	131
Figure 5.37 Tassement observé et prédit par le modèle LSTM- 1 input (Ma13).	132
Figure 5.38 Performances du modèle LSTM- 1 input (Ma13).	132
Figure 5.39 Tassement observé et prédit par le model LSTM- 2 input (Ma13).	133
Figure 5.40 Les performances du model LSTM- 2 input (Ma13).	133
Figure 5.41 Tassement observé et prédit par le modèle LSTM- 7 input (Ma13).	134
Figure 5.42 Performances du modèle LSTM- 7 input (Ma13).	134
Figure 5.43 Topologie du modèle CNN utilisé.	134
Figure 5.44 Le tassement observé et prédit par le model CNN-1 input (Ma12).	135
Figure 5.45 Les performances du model CNN- 1 input (Ma12).	135
Figure 5.46 Tassement observé et prédit par le modèle CNN-2 input (Ma12).	136
Figure 5.47 Performances du modèle CNN-2 input (Ma12).	136
Figure 5.48 Tassement observé et prédit par le modèle CNN- 7 input (Ma12).	136
Figure 5.49 Performances du modèle CNN- 7 input (Ma12).	136
Figure 5.50 Tassement observé et prédit par le modèle CNN- 1 input (Ma13).	137
Figure 5.51 Performances du modèle CNN- 1 input (Ma13).	137
Figure 5.52 Tassement observé et prédit par le modèle CNN- 2 input (Ma13).	137
Figure 5.53 Performances du modèle CNN- 2 input (Ma13).	137
Figure 5.54 Tassement observé et prédit par le modèle CNN- 7 input (Ma13).	138
Figure 5.55 Performances du modèle CNN- 7 input (Ma13).	138
Figure 5.56 Performances du modèle MGGP-1 input (Ma12).	140
Figure 5.57 Pression interstitielle prédite par le modèle MGGP-2 input (Ma12).	141
Figure 5.58 Performances du model MGGP-2 input (Ma12).	141
Figure 5.59 Pression interstitielle prédite par le model MGGP-2 input (Ma12).	142
Figure 5.60 Performances du modèle MGGP-7 input (Ma12).	142
Figure 5.61 Pression interstitielle prédite par le modèle MGGP-7 input (Ma12).	142
Figure 5.62 Performances du modèle MGGP-1 input (Ma13).	143
Figure 5.63 Pression interstitielle prédite par le modèle MGGP-1 input.	143

Figure 5.64 Performances du model MGGP-2 input (Ma13).....	144
Figure 5.65 Pression interstitielle prédite par le modèle MGGP-2 input (Ma13).	144
Figure 5.66 Performances du modèle MGGP-7 input (Ma13).....	145
Figure 5.67 Pression interstitielle prédit par le model MGGP-7 input (Ma13).....	145
Figure 5.68 Pression interstitielle observée et prédite par le modèle LSTM-1 input (Ma12).	146
Figure 5.69 Performances du modèle LSTM-1 input (Ma12).....	146
Figure 5.70 Pression interstitielle observée et prédite par le modèle LSTM- 2 input (Ma12).	147
Figure 5.71 Performances du modèle LSTM- 2 input (Ma12).....	147
Figure 5.72 Pression interstitielle observée et prédite par le modèle LSTM- 7 input (Ma12).	147
Figure 5.73 Performances du modèle LSTM-7 input (Ma12).....	147
Figure 5.74 Pression interstitielle observé et prédit par le modèle LSTM- 1 input (Ma13).....	148
Figure 5.75 Performances du modèle LSTM- 1 input (Ma13).....	148
Figure 5.76 Pression interstitielle observée et prédite par le modèle LSTM- 2 input (Ma13).	149
Figure 5.77 Performances du modèle LSTM- 2 input (Ma13).....	149
Figure 5.78 Pression interstitielle observée et prédite par le model LSTM- 7 input (Ma13).....	149
Figure 5.79 Performances du modèle LSTM- 7 input (Ma13).....	149
Figure 5.80 Pression interstitielle observée et prédite par le modèle CNN- 1 input (Ma12).	150
Figure 5.81 Performances du modèle CNN-1input (Ma12).....	150
Figure 5.82 Pression interstitielle observée et prédite par le modèle CNN- 2 input (Ma12).	151
Figure 5.83 Performances du modèle CNN- 2 input (Ma12).....	151
Figure 5.84 Pression interstitielle observée et prédite par modèle CNN- 7 input (Ma12).	151
Figure 5.85 Performances du modèle CNN- 7 input (Ma12).	151
Figure 5.86 Pression interstitielle observée et prédite par le modèle CNN- 1 input (Ma13).	152
Figure 5.87 Performances du modèle CNN- 1 input (Ma13).....	152
Figure 5.88 La pression interstitielle observé et prédit par le model CNN- 2 input (Ma13).....	153
Figure 5.89 Les performances du model CNN- 2 input (Ma13).	153
Figure 5.90 La pression interstitielle observé et prédit par le model CNN- 7 input (Ma13).....	153
Figure 5.91 Les performances du model CNN- 7 input (Ma13).	153

LISTE DES TABLEAUX

Tableau 1.1	Corrélation sur les paramètres de compressibilité et consolidation.....	22
Tableau 2.1	Modèles de comportement et leurs applications pratiques.	41
Tableau 2.2	Méthodes développées pour résoudre des problèmes d'optimisation.	49
Tableau 3.1	Références des méta-heuristiques et leurs inspirations Méta-heuristiques.....	66
Tableau 3.2	Analogie entre un problème d'optimisation et un système physique (Dréo et al., 2003)..	67
Tableau 3.3	l'utilisation des méta-heuristiques.	74
Tableau 4.1	Variation et valeurs moyennes des propriétés des sols étudiés.	82
Tableau 4.2	Erreurs absolues moyennes du test pour les modèles RNA	85
Tableau 4.3	Paramètres du modèles NG	87
Tableau 4.4	Les erreurs absolues moyennes du test pour les modèles NG.	87
Tableau 4.5	Performances des modelés empiriques et développés.	91
Tableau 4.6	Les plages de variation des paramètres	92
Tableau 4.7	Comparaison entre les valeurs mesurées et prédites par NN-PSO	94
Tableau 4.8	les paramètres du model MGGP.....	96
Tableau 4.9	Comparaison entre les modèles NN-PSO et MGGP	98
Tableau 4.10	Paramètres du model SSCM avant identification (Arabet, 2011).	103
Tableau 4.11	Paramètres du modèle SSCM après identification.	104
Tableau 4.12	Paramètres du modèle SSCM avant identification selon Ganesalingam (2013)	104
Tableau 4.13	Paramètres du modèle SSCM après identification.	105
Tableau 4.14	Propriétés physiques, chimiques et hydriques du sol Michali (1994)	106
Tableau 4.15	Paramètres du modèle SSCM avant identification selon Michali (1994).....	108
Tableau 4.16	Paramètres du modèle SSCM après identification.	110
Tableau 5.1	Propriétés physiques et chimiques du sol (Mesri et al. 2015)	116
Tableau 5.2	Fonctions obtenues à partir du modèle MTM	119
Tableau 5.3	Fonctions objectives.	120
Tableau 5.4	Fonctions obtenues à partir du modèle MTM	121
Tableau 5.5	Fonctions objectives.	121
Tableau 5.6	Évaluation du modèle LSTM-1 (Ma12).	130
Tableau 5.7	Évaluation du modèle LSTM- 2 input (Ma12).....	130
Tableau 5.8	Évaluation du modèle LSTM- 7 input (Ma12).....	131
Tableau 5.9	Évaluation du modèle LSTM- 1 input (Ma13).....	132
Tableau 5.10	Évaluation du modèle LSTM- 2 (Ma13).	133
Tableau 5.11	Évaluation du modèle LSTM- 7 input (Ma13).	133
Tableau 5.12	Évaluation du modèle CNN- 1 (Ma12).	135

Tableau 5.13 Évaluation du modèle CNN- 2 input (Ma12).	135
Tableau 5.14 Évaluation du modèle CNN- 7 input (Ma12).	136
Tableau 5.15 Évaluation du modèle CNN- 1 input (Ma13).	137
Tableau 5.16 Évaluation du modèle CNN- 2 input (Ma13).	137
Tableau 5.17 Évaluation du model CNN- 1 input appliquer sur la couche Ma13.	138
Tableau 5.18 Comparaison entre les approches développées et les méthodes existantes.	139
Tableau 5.19 Évaluation du modèle LSTM- 1 input (Ma12).	146
Tableau 5.20 Évaluation du modèle LSTM- 2 input (Ma12).	147
Tableau 5.21 Évaluation du modèle LSTM- 7 input (Ma12).	147
Tableau 5.22 Évaluation du modèle LSTM- 1 input (Ma13).	148
Tableau 5.23 Évaluation du model LSTM- 2 input appliquer sur la couche Ma13.	148
Tableau 5.24 Évaluation du model LSTM- 7 input (Ma13).	149
Tableau 5.25 Évaluation du modèle CNN- 1 input (Ma12).	150
Tableau 5.26 Évaluation du model CNN- 2 input (Ma12).	150
Tableau 5.27 Évaluation du modèle CNN- 7 input (Ma12).	151
Tableau 5.28 Évaluation du modèle CNN- 1 input (Ma13).	152
Tableau 5.29 Évaluation du modèle CNN- 2 input (Ma13).	152
Tableau 5.30 Évaluation du modèle CNN- 7 input (Ma13).	153
Tableau 5.31 Comparaison entre les approches développées et les méthodes existantes.	154

INTRODUCTION GÉNÉRALE

Classiquement, la déformation des sols fins au cours du temps se compose d'une phase de consolidation correspondant à la dissipation de la surpression interstitielle, dite consolidation ou compression primaire, suivie d'une phase, dite compression ou de consolidation secondaire ou fluage. Pendant cette seconde phase, la surpression interstitielle s'est dissipée et la contrainte effective demeurera constante. Diverses études expérimentales ont montré que la différence entre ces deux phases n'est pas aussi claire qu'on peut le penser (Ladd et al., 1977), le processus de déformation du sol au niveau microscopique étant fondamentalement le même pendant la consolidation primaire et le fluage. Les deux phases se distinguent principalement par la variation ou non de la contrainte effective supportée par les particules du sol. Ce comportement complexe et différé de ces sols complique le travail des ingénieurs praticiens pour le dimensionnement des ouvrages. Ils s'orientent souvent vers des méthodes plus ou moins empiriques qui donnent parfois satisfaction mais dont le fondement théorique n'est pas solide.

Face à ces difficultés, les chercheurs n'ont cessé de faire évoluer les connaissances théoriques et pratiques en géotechnique. Le chemin parcouru depuis les travaux de Terzaghi est très important. Cette évolution a été aidée par deux facteurs principaux. Le premier facteur est le développement technologique qui a mis à disposition des ordinateurs de plus en plus puissants mais aussi des machines d'essais de plus en plus perfectionnées. Le second facteur est l'évolution réalisée dans les méthodes de calcul numériques et spécialement dans la méthode des éléments finis. Ce développement a permis aussi l'utilisation de modèles rhéologiques de plus en plus complexes pour représenter les sols et ces modèles nécessitent la détermination de nombreux paramètres. Cette détermination pose de nouvelles difficultés. En effet, la mesure de ces paramètres à partir des essais de laboratoire pose le problème de représentativité des échantillons prélevés et les effets du remaniement induit par les opérations de forage, d'extraction et de découpe.

C'est dans ce contexte qu'est née la problématique de cette thèse. Pour répondre à cette problématique, nous avons proposé deux méthodes d'identification de paramètres, basées sur l'intelligence artificielle. La première consiste à résoudre le problème direct par apprentissage automatique à l'aide des réseaux neurones artificiels, les réseaux de neurones hybrides avec les métas heuristiques et la programmation génétique. La seconde méthode consiste à résoudre le problème inverse par ajustement d'un modèle numérique sur des données expérimentales mesurées. La qualité de l'ajustement est évaluée par une fonction erreur qui caractérise l'écart entre le modèle numérique et l'expérience. Les valeurs des paramètres du modèle constitutif du sont obtenues par minimisation de la fonction erreur.

La conduite de ce travail a nécessité la manipulation des données importantes en volume mais variées aussi surtout lors de l'utilisation des d'apprentissage pour les réseaux neurones, les approches hybrides et la programmation génétique. Ceci nous a conduits à développer des bases de données et caractériser d'une manière adaptée les matériaux d'étude. Ces bases de données ont nécessité au préalable des études paramétriques et la mise en place d'une normalisation intelligente.

Les techniques évoquées ci-dessus vont être appliquée à explorer le phénomène du fluage. Pour cela, le travail a consisté à analyser et prévoir le comportement du sol à court, à moyen et long terme. Afin de prendre en compte de la complexité mentionnée ci-dessus, deux détecteurs par apprentissage profond (LSTM, CNN) ont été utilisés. Les modèles élaborés visent à apporter des éléments qui permettent de mieux comprendre la nature particulière du fluage.

Pour présenter le travail, il a été décidé d'organiser cette thèse en cinq chapitres. Les trois premiers chapitres font la part belle à la synthèse bibliographique.

Ainsi, **le chapitre 1** délimite le cadre théorique relatif aux recherches menées sur l'interprétation du fluage dans le but d'estimer les déformations différées. Un aperçu historique a été exposé et une analyse détaillée des aspects pratiques est présentée.

Le chapitre 2 présente en détail les modèles de comportement des sols employés dans l'analyse directe et l'analyse inverse. Au départ, ce sont les modèles les plus utilisés pour l'étude des sols compressibles qui sont présentés. Ensuite, ce sont quelques modèles avancés spécifique au fluage qui seront listés. Ce chapitre expose aussi, en plus de notions fondamentales sur l'apport de l'analyse inverse en géotechnique, les différentes méthodes d'optimisation couramment employées dans la littérature.

Le chapitre 3 est réservé à la présentation de l'outil de base exploré dans cette thèse qui est celui de l'intelligence artificielle et surtout son application en géotechnique. En tenant compte des définitions préalables d'optimisation du chapitre précédent, les différentes méta-heuristiques et les méthodes d'apprentissage profond, également connues sous le nom « Deep learning » sont analysées. Ensuite, une classification des méta-heuristiques en allant d'une simple recherche locale à une recherche globale complexe est donnée. Nous expliquons par la suite le mode d'hybridation des méta-heuristiques. A la fin de ce chapitre, nous terminerons par une synthèse sur les différents indicateurs techniques destinés à résoudre les problèmes prédictifs pour mettre en évidence l'originalité des contributions proposées dans le chapitre suivant. Le post-traitement statistique par analyse de régression mis en place pour interpréter les résultats d'une telle optimisation fait aussi l'objet du présent chapitre. Pour rappel, notre contribution s'articule autour d'une identification des propriétés du sol et une prédiction du tassement à long terme sur la base des algorithmes élaborés pour des situations réelles et des ouvrages de grande importance déjà en exploitation.

Le quatrième chapitre est consacré à la conception des modèles prédictifs des paramètres de compressibilité (C_c , C_α) par l'utilisation des réseaux de neurones artificiels, les réseaux neurones hybrides avec méta-heuristique : algorithme génétique (AG) et optimisation essaim particulaire (PSO). La dernière version de la programmation génétique (MGGP) a fait aussi l'objet d'une application pour une bonne prédiction des mêmes paramètres. Une analyse critique des résultats des simulations en comparant la performance des algorithmes proposés RNA, Neuro-génétique, NN-PSO, et MGGP avec d'autres expressions empiriques classiques (la régression simple et multiple) justifient la méthodologie choisie et met en exergue les limites de chaque technique. Ce chapitre se poursuit par une étude sur l'identification des paramètres de sol du remblai B de Cubzac-les-Ponts par une analyse inverse optimisée par un algorithme génétique. Cet exemple permet de tester la capacité du programme à la résolution des problèmes géotechniques.

Le cinquième et dernier chapitre traite de la prédiction du comportement de l'aéroport de Kansai, situé sur un épais dépôt d'argile, à court, moyen et long terme. Une comparaison des résultats mesurés à ceux calculés est réalisée. De plus, une prévision de la pression interstitielle dans des

conditions réelles est présentée. Ces résultats sont accompagnés d'une comparaison avec d'autres méthodes d'analyse existantes.

La conclusion générale dresse le bilan du travail tout en commentant les questions traitées dans les différents chapitres et les réponses qui ont été apportées. À la lumière des résultats obtenus, des perspectives pour la poursuite de ce travail sont présentées.

CHAPITRE 1

ETAT DE CONNAISSANCES SUR LE FLUAGE DES SOLS ARGILEUX

1 Introduction

Le comportement visqueux des sols fins pose de nombreuses difficultés aux géotechniciens et aux praticiens de la construction à cause de la complexité des déformations qui se produisent quand ces derniers sont sollicités. Les nombreux dégâts constatés sur quelques ouvrages géotechniques suite aux variations volumiques de ce type de sol ont incité les chercheurs à s'y intéresser et à étudier le comportement de ce type de sols et particulièrement quand il s'agit des déformations différées dites fluage. Depuis plus de trois décennies, d'énormes progrès ont été réalisés que ça soit sur le plan théorique ou sur le plan expérimental. Ces recherches visent essentiellement à fournir aux projeteurs des règles et normes pratiques pour le calcul des ouvrages. C'est dans ce sens que ce chapitre a été réservé à présenter ce phénomène qu'est le fluage. Un aperçu sur les progrès des aspects expérimentaux et numériques réalisés dans l'analyse de ce phénomène est donné au départ. Ensuite, ce sont les définitions et les considérations théoriques du phénomène qui ont été abordées. La dernière section expose les méthodes qui permettent de prédire le tassement à long terme avec leur domaine d'applications et leurs limites d'utilisation.

2 Revue de littérature

Depuis les premiers travaux de Frontard (1914), Terzaghi (1923) et Biot (1941), la consolidation des argiles a toujours suscité l'intérêt des géotechniciens. Cet intérêt s'est accentué avec le temps et plus particulièrement à partir des années 1950, à cause du nombre grandissant d'ouvrages réalisés dans des conditions complexes et sous des sollicitations sévères sur des sols argileux sujets à la consolidation et au fluage.

Hanna (1950), qui a effectué des recherches à l'université Fouad I, au Caire, a constaté que les tassements expérimentaux, basés sur les résultats des essais de consolidation, étaient de 3 à 4 fois plus grandes que les valeurs observées. Cette différence, elle l'a attribuée à la perturbation de l'échantillon lors des prélèvements. Pour remédier au problème, l'auteur a développé un échantillonneur capable de consolider le sol sur place.

Sheeran et Krizek (1971) ont expliqué les techniques et les étapes qu'ils ont effectuées au laboratoire pour confectionner une éprouvette intacte d'un sol cohésif sous une forme adaptée à l'essai œdométrique. Leurs travaux ont été résumés dans un document de référence élaboré à l'université Northwestern (USA) et portant sur l'échantillonnage et la préparation d'une éprouvette intacte pour l'étude de la consolidation et la compressibilité d'un sol.

Mesri (1973) a examiné l'importance considérable de la compression secondaire. Il a noté que la compression secondaire peut être complètement interprétée et expliquée par la donnée d'un coefficient noté C_α . Il a aussi montré que la composition minérale et l'environnement physicochimique du matériau sont susceptibles d'exercer une influence significative sur le tassement secondaire.

C_α est défini comme la pente de la courbe de déformation en fonction du logarithme du temps au début de la compression secondaire.

Sridharan et Rao (1973) ont noté que la contrainte effective, la contrainte de préconsolidation et la température sont des facteurs extrêmement importants. Elles ont une influence considérable sur le coefficient C_α , dit aussi indice de compression secondaire. Les auteurs ont proposé un schéma de comparaison pour classer les sols en fonction de leurs compressibilités.

Davies et Dennison (1975), après une étude sur des argiles remaniées, ont conclu que le coefficient C_α est un paramètre constant pour une argile donnée pour des valeurs des contraintes effectives excédant la pression de préconsolidation.

Mesri et Godlewski (1977) ont analysé des données de consolidation provenant de trois dépôts des sols naturels et ont trouvé une relation unique et constante entre l'indice de compression et l'indice de compression secondaire C_α / C_c égale à 0,10.

Sridharan et Rao (1982) ont signalé que le coefficient de compression secondaire diminuait avec l'augmentation de la contrainte effective, la diminution de l'incrément de la contrainte appliquée et la diminution de l'indice de vides.

Mesri et Castro (1987) se sont concentrés sur le rapport C_α / C_c pour décrire le comportement de compression secondaire du sol.

Dhowian (1991) a proposé un modèle rhéologique pour prédire la compression primaire et la compression secondaire des sols de la sebka (site à Jizan en Arabie Saoudite). Il a constaté que la compression secondaire représente une partie importante du tassement total. Le résultat de la compression primaire et secondaire prédit par le modèle rhéologique n'a pas montré de différence par rapport aux mesures effectuées en place et au laboratoire.

Fox et al. (1992) ont réalisé des essais œdométriques à long terme sur la tourbe de Middleton. Le but de ces essais était de suivre les tassements d'une éprouvette de sol soumise à une contrainte totale. Ils ont remarqué que la consolidation primaire est relativement rapide, que le tassement de fluage représente une part significative du tassement total et que la compression tertiaire est clairement visible après la compression secondaire, ce qui laisse penser que le coefficient C_α n'est pas constant mais augmente avec le temps.

Leroueil (1996) a présenté une synthèse sur les aspects fondamentaux et pratiques de la compressibilité des argiles. Les tests pratiques effectués par l'auteur ont démontré que plusieurs facteurs influent sur la compressibilité des argiles naturelles, telle que la vitesse de déformation, la température, perturbation de l'échantillonnage, chemin des contraintes et phénomènes structurants.

Leroueil et al. (1996) ont proposé une caractérisation géotechnique des types de mouvements à savoir des mouvements de pré-rupture, de rupture, de post-rupture et de réactivation. En pré-rupture, le fluage est réparti sur toute la masse du sol, la rupture étant caractérisée par la formation de bandes de cisaillement où le fluage sera concentré. Pour le mouvement de réactivation, il s'agit pour l'essentiel du fluage d'un bloc rigide sur un autre bloc rigide, le mouvement est localisé sur des bandes préexistantes. Les mouvements en post-rupture, sont les mouvements entre la rupture et la ruine totale du matériau.

Mesri et al. (1997) ont mené une série d'essais œdométriques sur des échantillons intacts de tourbe de Middleton avec et sans chargement pour étudier la compression secondaire. Dans leurs études, les auteurs ont montré que le comportement de ce sol obéit au concept de compressibilité C_α / C_c constant. Les valeurs les plus basses de C_α ont été rencontrées dans la plage de recompression où C_c est petit. Les valeurs élevées de C_α ont été observées à des contraintes verticales effectives au voisinage de la contrainte de préconsolidation où C_c est élevé.

Al-Shamrani (1998) a réalisé une série de tests sur des échantillons naturels. Les résultats de consolidation unidimensionnelle montrent que l'indice de compression secondaire (C_α) est

fortement dépendant de la contrainte effective. Une augmentation rapide de C_α s'établit lorsque la contrainte effective augmente pour se stabiliser ensuite à un niveau constant.

Sridharan et Prakash (1998) ont proposé une estimation du tassement secondaire basée sur un facteur de compression secondaire m :

$$m = \frac{\Delta \log e}{\Delta \log t}$$

Dans cette formule, e est l'indice des vides et t le temps.

Cette méthode est plus réaliste pour un sol qui présente un comportement non linéaire.

Magnan et al. (2001), suite à des essais œdométriques sur des argiles intactes provenant de deux sites différents, concluent que le coefficient C_α augmente pour des contraintes inférieures à la contrainte de préconsolidation pour décroître ensuite.

Mesri (2003) a mis l'accent sur la compression primaire et secondaire d'un sol saturé. Il suggère que le fluage ne se produit qu'après la fin de la consolidation primaire, c'est-à-dire après la dissipation de la pression interstitielle et que, par conséquent, la courbe de déformation-temps ne dépend pas de la durée de la consolidation.

Phanikumar et Sharma (2007) ont étudié l'effet des cendres volantes sur le changement de volume de deux types différents d'argiles (argile gonflante hautement plastique et argile non gonflante). Les auteurs soulignent que dans l'argile mélangée à des cendres volantes, le temps nécessaire pour la fin de la consolidation primaire et le début de la consolidation secondaire est raccourci. Cela réduit le temps nécessaire pour atteindre le tassement final.

Bhattacharya et Basack (2011) ont suggéré l'installation de drains verticaux préfabriqués et la mise en place d'un pré-chargement qui accélèrent la consolidation des sols meubles ayant une faible conductivité hydraulique et une faible résistance au cisaillement, réduisant ainsi la période de temps par accélération du phénomène de consolidation.

Yin et al. (2017), ont suggéré que le coefficient C_α n'est pas constant. Ils attribuent cela à la dégradation des liaisons inter-particulaires du squelette solide due au fluage. Ils pensent que ce coefficient devrait être lié à la microstructure des argiles.

Kaddouri et al. (2018) ont étudié l'effet de la température sur le fluage d'une argile compactée. Un nouvel appareil a été développé pour contrôler la température entre 5 et 70° C. Les résultats ont montré que lorsque la température augmente de 5 à 70° C, le coefficient de fluage augmente de 14%.

3 Considérations théoriques

3.1 Niveaux de déformation

Au sens rhéologique, la structure des sols dépend de la disposition des particules dans l'espace, de la position de contact entre les particules, de l'amplitude et la direction des forces élémentaires agissant sur ces points de contact. Dans ces milieux, les phénomènes de déformation passent par quatre niveaux : moléculaire, particulaire, structural et au niveau de l'agrégat (Ter-Stepanian, 1996).

3.1.1 Niveau moléculaire de la déformation du sol

Au niveau moléculaire, la déformation consiste en un déplacement des unités d'écoulements lorsque les barrières d'énergie sont surmontées (Figure 1.1). Ce phénomène déterministe se produit

avec une vitesse constante décrite par l'équation d'Eyring-Mitchell (Mitchell 1964, 1993 cité par Elhussein, 2001):

$$\dot{\gamma} = X \frac{KT}{h} \exp\left(\frac{-E}{R_0T}\right) \exp\left(\frac{\lambda f_0}{2KT}\right) \quad (1.1)$$

Où X est un coefficient de proportionnalité, k est la constante de Boltzman $k=1,38.10^{-23} \text{J. K}^{-1}$; h est la constante de Planck $h=6,624.10^{-34} \text{J.s}^{-1}$; T est la température absolue (en Kelvin); R_0 est la constante universelle des gaz parfaits, $R_0=8,3144 \text{J. K}^{-1} \text{mol}^{-1}$; λ est la distance qui sépare deux positions d'équilibre successives; E est l'énergie libre d'activation; f_0 est la force moyenne agissant sur chaque unité d'écoulement. La valeur de f_0 est constante pour une structure de sol donné. La vitesse de fluage au niveau moléculaire pour chaque structure de sol est donc supposée constante.

3.1.2 Le niveau des particules de la déformation du sol

La déformation au niveau des particules est un déplacement mutuel des particules à l'initiation et à la rupture des liaisons entre elles. Ce déplacement ne modifie pas de manière significative la disposition mutuelle des particules (Figure 1.2). Ce phénomène répond principalement à des facteurs liés à la dispersion du sol, à la déformabilité et à la durée de vie des liaisons faibles entre les particules et aux contraintes de cisaillement.




Figure 1.1 Niveau moléculaire de la déformation (Poppe et al., 2018).




Figure 1.2 Niveau de la déformation des particules du sol (Herling et Breu, 2014)

3.1.3 Le niveau structural de la déformation du sol

La déformation et la vitesse de fluage sont liées par une relation bien définie. La nature de cette dépendance n'est pas encore bien comprise, mais son existence a été prouvée expérimentalement par tous les tests réalisés par Ter-Stepanian (1996). Cette dépendance est définie par des tendances du développement conditionnées par la causalité. Le rapport est exprimé par des courbes intrinsèques obtenues par l'auteur. Pour chaque structure de sol, le phénomène de fluage se produit et au-delà d'une certaine quantité, la structure du sol devient inadéquate. Une réorganisation de la structure se produit alors et le phénomène reprend son cours selon le principe de «Le Chatelier» qui stipule que tout système à qui on impose des changements extérieurs tend à minimiser leurs effets en retrouvant un nouvel état d'équilibre (Figure 1.3).




Figure 1.3 Niveau structural de la déformation du sol.

3.1.4 La déformation du sol au niveau des agrégats

Les valeurs probabilistes des caractéristiques mécaniques des sols qui résultent d'une réorganisation de la structure ne doivent pas être interprétées comme si le principe de causalité a été annulé. Ils doivent être considérés comme des causalités montrant des tendances de développement, plutôt que comme un signe de résultats précis et clairs. La probabilité d'atteindre des valeurs fortuites doit plutôt être comprise comme une certaine érosion de leur valeur décrite par des intervalles plus ou moins étroits.

Sur la base des paragraphes précédents, on peut conclure que les sols présentent divers comportements rhéologiques en fonction du niveau des contraintes appliquées. Dans tous les cas, les sols produisent d'abord un tassement primaire qui s'arrête lorsque la pression interstitielle est dissipée. Ce n'est pas le cas des sols fluant, qui produisent un tassement à long terme. C'est le phénomène de compression secondaire appelé aussi fluage.

3.2 Le fluage du sol

Le fluage d'un matériau quelconque est la déformation qui se produit au fil du temps lorsqu'il est soumis à un état de contrainte permanente. En raison de sa nature polyphasique, l'application de cette définition aux sols pose certains problèmes. Séparément, le sol qui peut être décomposé en un squelette formé de particules solides liées par l'eau plus ou moins adsorbée et à l'eau interstitielle libre, peut sous l'effet de certains états de contraintes et pendant une certaine période, varier de volume en changeant de composition relative; l'eau s'écoule hors des frontières du massif suivant les lois de la filtration à travers les milieux poreux, c'est le phénomène de consolidation dite primaire. On peut admettre cette définition pour le fluage des sols. En fait, les phénomènes régissant le fluage sont nombreux et de nature très différente. On peut les décomposer en :

- ❖ Déformation du squelette inter-granulaire par réarrangement relatif des particules sous l'effet des charges extérieures et de la pression interstitielle.
- ❖ Evacuation de l'eau sous l'effet des gradients hydrauliques suite aux surpressions interstitielles apparues après chargement extérieur.

Par conséquent, le fluage d'un sol est alors la déformation du squelette inter-granulaire au cours du temps sous l'action combinés et antagonique des charges externes et de la pression interstitielle. La contrainte produite par ces deux facteurs peut être constante ou variable dans le temps. Cette définition du fluage du sol est similaire à tout autre matériau, la pression interstitielle pour ces derniers est nulle pendant toute la déformation du squelette.

3.2.1 Les catégories de la déformation due au fluage

Les recherches théoriques et expérimentales sur la relation entre contrainte et déformation de fluage ne peuvent être généralisées. Les lois de fluage sont étudiées en laboratoire pour les conditions aux limites des contraintes et déformations simples. À travers toutes les études menées, trois grandes catégories de déformations ont été suggérées :

- ❖ La déformation volumique ;
- ❖ La déformation de cisaillement ;
- ❖ La déformation généralisée ;

A cette distinction, il y a plusieurs raisons. Par analogie avec la théorie de l'élasticité, on peut soutenir que la déformation volumique n'est causée que par la composante isotrope du tenseur de contrainte alors que la déformation par cisaillement est causée uniquement par la partie déviatrice du tenseur de contrainte en ce point.

3.2.1.1 Le fluage en déformation volumique :

Dans le cas des sols saturés, la contrainte appliquée est répartie en deux systèmes de contraintes, l'un appliqué au squelette inter-granulaire, l'autre à l'eau libre interstitielle. Si ces tenseurs de contraintes sont isotropes, la déformation volumique présente deux particularités qui vont influencer grandement sur l'étude du fluage :

- ❖ L'eau libre interstitielle étant en pression, un écoulement se produira pourvu que les conditions de drainage aux limites du massif permettent l'apparition de gradients hydrauliques. Un écoulement d'eau signifie une déformation volumique du sol par changement de sa composition relative.
- ❖ Le squelette inter-granulaire sous l'effet des contraintes isotropes qu'il subit, change de volume, les particules minérales se rapprochent, les vides interstitiels diminuent, ce phénomène change de nature dès que le volume des vides devient quasiment nul puisque la compressibilité du squelette devient brusquement égale à la compressibilité des particules minérales.

3.2.1.2 Le fluage de cisaillement

Dans un milieu continu, l'état de contrainte en un point est un état de cisaillement pur si la partie isotrope du tenseur de contrainte en ce point est nulle. Dans des conditions proches de l'état idéal de cisaillement pur, l'étude du fluage par cisaillement aura les particularités suivantes :

- ❖ La pression interstitielle est un paramètre qui n'influe pas sur les lois de la déformation, puisque, sa valeur reste théoriquement nulle.
- ❖ La déformation de cisaillement du squelette inter-granulaire ne présente pas de limite absolue : elle est amortie, ou dans certaines conditions, elle aboutit à un réarrangement des liaisons mécaniques entre particules.

3.2.1.3 La déformation de fluage généralisé :

Dans le temps, la déformation d'un matériau soumis à un état de contrainte complexe n'est pas égale à la superposition de la déformation volumique qui serait causée par la partie isotrope du tenseur de contrainte et de la déformation causée par la partie déviatrice (cisaillement pur). En effet, il existe une interaction entre les différentes composantes du tenseur, ce qui, entre autres,

conduit non seulement à relier les lois du fluage à l'état de contrainte appliquée, mais également à l'histoire des différents états des contraintes antérieurs.

3.2.2 Effets du temps

L'influence du temps sur le comportement des sols argileux dépend plus ou moins de la structure, la consistance et la compacité du sol considéré. En pratique, l'influence du temps a été analysée à partir de deux aspects différents :

- ❖ Les effets de l'âge ou du vieillissement : Taylor (1942) puis Bjerrum (1967) ont montré que sous des contraintes effectives constantes ou légèrement variables, le vieillissement de l'argile conduit à l'apparition de nouvelles liaisons inter-granulaires rigides qui renforcent la structure du squelette solide, entraînant une réduction de leur indice de vide par suite des déformations de fluage qu'elles subissent. La diminution de l'indice de vides d'une argile donnée s'accompagne d'une augmentation de sa pression de pré-consolidation et donc de sa résistance structurale. Cet effet semble très évident: pour les argiles plastiques, l'augmentation de la résistance due au vieillissement étant proportionnelle à celle de leur pression de pré-consolidation. La figure 1.4 illustre schématiquement l'effet du temps sur les caractéristiques de compressibilité et de consolidation d'une argile naturelle.
- ❖ L'effet de la vitesse de chargement ou de la durée de chargement : Crawford (1965) et Bjerrum (1967) ont montré que lorsque le temps de chargement augmente, la pression apparente de préconsolidation de l'argile naturelle diminue, et vice versa. Il semble que ce phénomène soit dû à une autre matérialisation du phénomène de la compression secondaire qui est associé au vieillissement de l'argile. En revanche, une diminution de la vitesse de chargement, c'est-à-dire de la vitesse de déformation de l'argile, correspond à une augmentation de la durée d'application des charges, ce qui entraînerait une diminution non seulement de la pression de préconsolidation de l'argile, mais également de tous les seuils qui définissent sa courbe d'état limite (Figure 1.5).

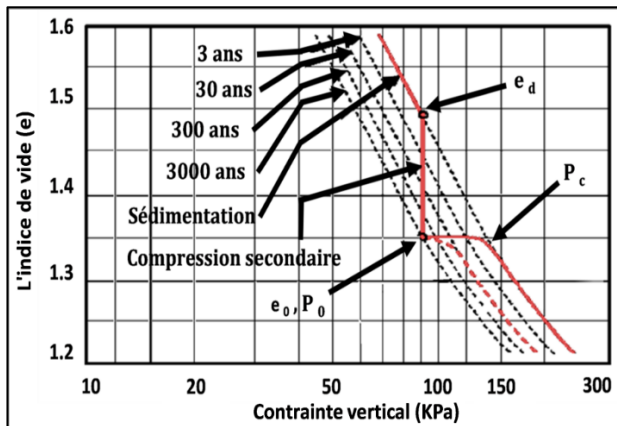


Figure 1.4 Histoire géologique et compressibilité des argiles naturelles (Bjerrum, 1967).




Figure 1.5 Courbe d'état limite d'une argile naturelle (Bjerrum, 1967).

3.2.3 L'effet de niveau de contrainte

Afin de définir plus précisément les caractéristiques unidimensionnelles des argiles molles, divers types d'essais œdométriques ont été effectués par Leroueil et al. (1985) sur des argiles de l'est du Canada. Les résultats obtenus montrent que la compression des argiles augmente progressivement avec l'augmentation de niveau de la contrainte de consolidation. Sous les plus fortes contraintes (excédant la pression de consolidation), les courbes ont une forme en S typique. Par contre, sous des faibles contraintes et autour de la pression de pré-consolidation, les courbes

représentant la variation volumique en fonction du temps (ε_v -log(t)) ont une pente stabilisée (du moins durant la durée des essais).

3.3 Théories du fluage

3.3.1 Compression Secondaire vs Consolidation Secondaire

Lorsque le terme « consolidation secondaire » a été adopté par les praticiens en géotechnique, Lo (1961) a déclaré que ce terme n'est pas adapté car les tassements de compression secondaire se produisent sous des pressions interstitielles non mesurables (c'est-à-dire négligeables) et peuvent donc difficilement être attribués au processus de consolidation. Leonards (1977) a apporté des éclaircissements supplémentaires sur le sens de la consolidation et de la compression. Il a déclaré que, compte tenu de la définition de Terzaghi, le terme « compression » implique toute forme de réduction de volume et que la « consolidation » est un type particulier de compression qui s'accompagne d'une augmentation significative de la contrainte effective due à la réduction correspondante des pressions interstitielles. Le terme « consolidation primaire » est raisonnable car une diminution de volume est attribuable à une augmentation des contraintes effectives. Cependant, le terme « consolidation secondaire » n'est pas raisonnable car, dans ce cas, le volume diminue alors que la contrainte effective reste constante. Dans certains cas, le fluage peut être modélisé raisonnablement en utilisant les théories de la viscoélasticité ou viscoplasticité. Pour ces modèles, le fluage est représenté par un élément visqueux, c'est-à-dire la contrainte est liée fonctionnellement au taux de déformation. Ces modèles sont développés en incluant des composants rhéologiques visqueux.

3.3.2 La Théorie de Buisman

En 1936, Keverling Buisman le premier professeur de mécanique des sols à l'université de Delft (Pays-Bas), a utilisé le terme « effet différé » pour décrire les déformations après la dissipation des pressions interstitielles. Des essais de consolidation à long terme ont été menés au laboratoire. L'auteur a découvert que les déformations ne se stabilisent pas à une valeur constante mais se présentent sous la forme d'une droite sur une échelle semi-logarithmique (log temps-déformation). Buisman, a alors proposé une formule semi-empirique basée sur ces mesures pour estimer le tassement secondaire. La formule semi-empirique proposée s'écrit sous la forme suivante:

$$\varepsilon = \varepsilon_p + \varepsilon_s \log \left(\frac{t}{t_0} \right) \quad (1.2)$$

Dans cette formule, ε_p désigne la déformation primaire, ε_s est la déformation secondaire, t_0 est un temps de référence (généralement 1 jour) et t le temps.

Après avoir introduit les constantes de compression primaire et secondaire, α_p et α_s , Buisman suppose également que la déformation est causée par une augmentation des contraintes effectives ($\Delta\sigma'$). L'équation finale a été exprimée par la formule ci-après:

$$z_t = h\Delta\sigma' \left[\alpha_p + \alpha_s \log \left(\frac{t}{t_0} \right) \right] \quad (1.3)$$

Dans cette formule, z_t désigne le tassement au temps t , h est l'épaisseur initiale de la couche, $\Delta\sigma'$ est l'incrément de contrainte effective, α_p est la constante de compression primaire, α_s est la constante de compression secondaire. Les constantes de compression doivent être calculées par unité d'épaisseur et de pression unitaire.

$$C_{\alpha} = -\frac{\Delta e}{\Delta \log(t)} \quad (1.4)$$

D'après l'approche de Buisman (1936), la valeur C_{α} dans l'équation (4) est constante. Cependant, il a été constaté que l'application de l'équation de consolidation de Buisman peut conduire à des prédictions de tassement peu satisfaisant en raison d'une surestimation significative des déformations à long terme. La théorie suppose implicitement que la compression secondaire commence au bout d'un jour ($t=1$ jour). Pour les dépôts de sol sur place ayant une épaisseur importante, la compression secondaire peut commencer beaucoup plus tard, c'est-à-dire que la théorie de Buisman donnera des prévisions de tassement artificiellement élevées dans ces cas. Une autre limitation de l'approche de Buisman est l'utilisation des valeurs constantes pour les coefficients α_p et α_s . Les coefficients de compression primaire et secondaire seraient dépendants du temps et de l'état de contrainte (Houkes, 2016).

3.3.3 La Théorie de Koppejan

Koppejan (1948) a combiné la loi de compression de Terzaghi avec l'expression de Buisman pour estimer les tassements secondaires. Il a proposé la formule suivante :

$$z_t = h \left(\frac{1}{C_p} + \frac{1}{C_s} \log(t) \right) \ln \frac{\sigma'_{v0} + \Delta \sigma'}{\sigma'_{v0}} \quad (1.5)$$

z_t désigne le tassement à l'instant t , h l'épaisseur initiale de la couche de sol, C_p le coefficient de compression primaire de Koppejan, C_s le coefficient de compression secondaire de Koppejan, σ'_{v0} la contrainte verticale initiale et $\Delta \sigma'$ l'incrément de contrainte. Houkes (2016) a discuté les limites de l'approche de Koppejan. Premièrement, les coefficients de compression C_p et C_s ne peuvent pas être constants. Deuxièmement, si la contrainte effective initiale est trop faible comparativement à l'incrément de charge, les déformations calculées seront excessivement élevées. Troisièmement, l'approche de Koppejan repose sur l'hypothèse implicite qui indiquait notamment que la compression secondaire se produit après un jour.

3.3.4 La Théorie de Mesri

Mesri et Godlewski (1977) ont mené une étude détaillée en vue de déterminer la relation entre C_{α} et C_c . Ils ont remarqué que le changement de volume s'est effectué au cours de la consolidation primaire et la compression secondaire en parfaite conformité avec le principe de contrainte effective de Terzaghi. Ils ont conclu leur travaux en notant que le coefficient C_{α} dépend fortement de la contrainte effective finale et que le rapport C_{α} / C_c , est constant. Mesri et Godlewski (1977) ont souligné que le coefficient C_{α} est donné par la pente de la courbe de l'indice des vides en fonction du logarithme du temps (e -log (t)) tandis que la valeur C_c est définie sur le tronçon normalement consolidé de la courbe œdométrique par la relation suivante :

$$C_c = -\frac{\Delta e}{\Delta \log(\sigma'_v)} \quad (1.6)$$

Choi (1982) puis Mesri et Castro (1987) constatent également que la valeur du coefficient C_{α} se rapproche de son maximum pour des contraintes effectives proches de la pression de pré-consolidation et qu'elle peut également évoluer avec le temps. Cependant, ces évolutions de la valeur du coefficient C_{α} s'accompagnent par des évolutions similaires des valeurs du coefficient C_c , permettant ainsi de maintenir le rapport C_{α} / C_c constant pour les sols étudiés.

3.3.5 La Théorie de Bjerrum

Bjerrum (1967) a étudié le fluage d'une argile provenant de la ville de Drammen en Norvège. Il a introduit les concepts de compression instantanée et de compression différée, puis il les a comparés au cadre de la consolidation primaire et la consolidation secondaire (voir Figure 1.6). La division de la compression en parties primaire et secondaire est considérée comme assez arbitraire (Bjerrum 1967) car le temps nécessaire à la dissipation des pressions interstitielles dépend de l'épaisseur de la couche d'argile, de la perméabilité et des conditions de drainage. Ainsi, Bjerrum (1967) estime que la division de la compression en parties primaire et secondaire ne permettait pas de décrire le comportement réel du sol.

3.3.6 Hypothèses A et B

Y a-t-il une relation unique entre l'indice des vides (déformation) et les contraintes effectives à la fin de la compression primaire (EOP) quelle que soit l'épaisseur de l'échantillon ? Terzaghi (1923) a assumé dans sa théorie de la consolidation que la réponse à cette question est positive. Cependant, cette théorie ne tient pas compte du fluage qui se produit après la dissipation de la surpression interstitielle. A cette question, deux hypothèses (A et B) sont formulées.

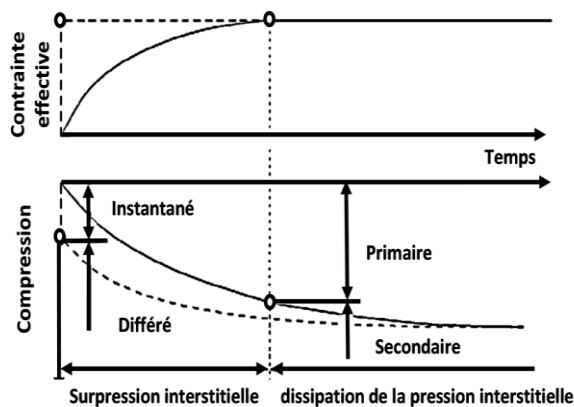


Figure 1.6 Le concept de compression primaire et secondaire (Bjerrum, 1967) adoptée par Bartholomeeusen (2003).

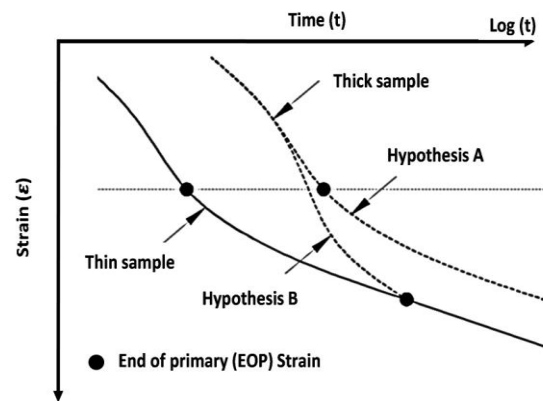


Figure 1.7 Présentation graphique de l'hypothèse A et B.

Dans l'hypothèse A, les déformations de la consolidation primaire sont associées uniquement au transfert des pressions interstitielles aux contraintes effectives et sont séparées des déformations dues à la compression secondaire (Figure 1.7). La théorie de consolidation de Terzaghi est utilisée pour calculer les tassements à la fin de la consolidation primaire, puis un coefficient de compression secondaire est utilisé pour calculer le tassement de fluage (Mesri et Choi, 1985). Dans l'hypothèse B, le fluage a lieu pendant et après le processus de la consolidation primaire. Les essais réalisés par Ladd et al. (1977) sur des monocouches d'épaisseurs différentes ont montré que l'évolution des déformations de consolidation se produisaient selon l'hypothèse B. En fait, ces essais ont montré que les tassements à la fin de la consolidation primaire dépendaient de la longueur de drainage.

3.4 Modèles analogiques de base

Un modèle rhéologique est un assemblage d'éléments simples qui permet de représenter un comportement mécanique de base. L'assemblage de ressorts, d'amortisseurs et de patins, d'une façon ou d'une autre, constitue la règle générale pour établir des modèles plus complexes. La réponse du modèle est indépendante du type de sollicitations imposées. Nous ne considérerons par la suite que les modèles qui décrivent le fluage.

3.4.1 Modèle de Newton

Le modèle de Newton est le modèle le plus simple qui intègre l'effet du temps. La viscosité dynamique η de l'amortisseur relie linéairement la contrainte de cisaillement τ à la vitesse de distorsion $\dot{\gamma}$ en cisaillement simple :

$$\tau = \eta \times \dot{\gamma} \tag{1.7}$$

Le modèle de Newton, représenté sur la Figure 1.8, décrit un fluage secondaire, dont la vitesse de déformation différée est fonction de la viscosité dynamique (η) du matériau. Ce modèle ne peut pas effectuer le processus de relaxation. Nous rappelons que la viscosité dynamique est exprimée en Poiseuille [P], équivalant au Pa.s.

3.4.2 Modèle de Maxwell

Le modèle de Maxwell correspond à la mise en série des modèles analogiques de Newton et Hooke (ressort élastique). La représentation correspondante est donnée à la figure 1.9.




Figure 1.8 Représentation du modèle analogique de Newton en cisaillement simple




Figure 1.9 Représentation analogique du modèle de Maxwell en cisaillement simple

Conformément au modèle de Newton et à l'élasticité linéaire en cisaillement simple, l'équation différentielle permettant de relier la contrainte de cisaillement τ , à la vitesse de distorsion ($\dot{\gamma}$) est :

$$\dot{\gamma} = \frac{\dot{\tau}}{G} + \frac{\tau}{\eta} \tag{1.8}$$

G est le module de cisaillement.

3.4.3 Modèle de Kelvin

Le modèle de Kelvin correspond à la mise en parallèle des modèles analogiques de Newton et Hooke. La représentation correspondante est donnée à la figure 1.10.

En cisaillement simple, la relation qui relie les contraintes aux déformations s'écrit :

$$\tau = G \times \gamma + \eta \times \dot{\gamma} \tag{1.9}$$

L'évolution de la distorsion au cours du temps est de type exponentiel amorti et présente une asymptote à long terme, caractérisant la distorsion élastique maximale du modèle de Hooke. En configuration mono-axiale, on aboutit à la relation suivante :

$$\sigma_{axiale} = E \times \epsilon_{axiale} + 2 \times \eta(1 + \nu) \times \dot{\epsilon}_{axiale} \tag{1.10}$$

3.4.4 Modèle de Burger

Le modèle de Burger correspond à la mise en série des modèles de Kelvin et de Maxwell comme indiqué sur la Figure 1.11.




Figure 1.10 Représentation du modèle analogique de Kelvin en cisaillement simple

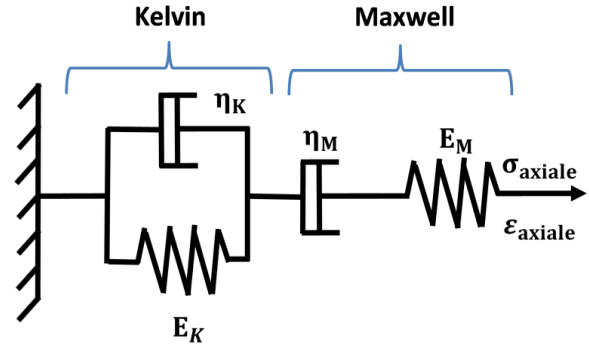


Figure 1.11 Représentation du modèle analogique de Burger en compression simple

En configuration de fluage uni-axiale, la déformation viscoélastique totale axiale (σ_{axiale}) combine celles des modèles de Kelvin et Maxwell et se décompose comme suit :

$$\varepsilon_{axiale}^{(t)} = \frac{\sigma_{axiale}}{E_M} + \frac{\sigma_{axiale}}{2\eta_M(1+\nu)} \cdot t + \frac{\sigma_{axiale}}{E_K} \left(1 - e^{\frac{-E_K}{2\eta_K(1+\nu)}t} \right) \quad (1.11)$$

Cette équation rend compte des phases de fluage primaire et secondaire. La phase de fluage secondaire s'exprime dès lors que les déformations différées qu'elle développe, sont du même ordre de grandeur que celles de la phase de fluage primaire. Jusqu'à présent, les modèles rhéologiques étudiés considèrent que les phénomènes différés se développent dès l'application d'une charge déviatorique quelconque. Nous allons maintenant introduire la notion de seuil de contrainte de déclenchement avec le modèle de Bingham.

3.4.5 Concept de Bingham

Le modèle analogique de Bingham considère un seuil de contrainte de cisaillement, σ_s , au-delà duquel seules des déformations différées peuvent se développer. Il est possible de représenter ce modèle par la figure 1.12, qui simule le seuil avec un patin parfait.

En configuration de cisaillement simple, la vitesse de distorsion $\dot{\gamma}$ s'écrit alors sous la forme :

$$\dot{\gamma} = \eta(\tau - \sigma_s) \quad \text{lorsque : } \tau \geq (\sigma_s) \quad (1.12)$$

$$\dot{\gamma} = 0 \quad \text{lorsque : } \tau \leq (\sigma_s) \quad (1.13)$$

Cette loi a été établie, de manière expérimentale. Elle ne fait intervenir que la valeur critique de la résistance en cisaillement σ_s , jouant un rôle de seuil de déclenchement de l'écoulement viscoplastique.

3.4.6 Modèle CVISC

Les modèles analogiques de base présentés aux paragraphes précédents sont de type viscoélastique non relaxant (Newton, Kelvin) et de type viscoélastique relaxant (Maxwell, Burger). Le modèle CVISC analogique est de type élasto-viscoplastique. Il est construit en associant en série le modèle de Burger et un patin plastique de type Mohr-Coulomb. La loi d'écoulement associée

permet de calculer les déformations plastiques irréversibles qui se forment instantanément et au cours du temps. Cela explique pourquoi ce modèle est plus réaliste pour les applications en ingénierie, particulièrement en géotechnique. La Figure 1.13 donne la représentation analogique de ce modèle.




Figure 1.12 Modèle analogique Bingham en cisaillement simple.

Figure 1.13 Modèle dérivé CVISC en compression simple.

Les paramètres du modèle CVISC sont les suivants :

- E_M : Module de cisaillement du modèle de Maxwell,
- E_K : Module de cisaillement du modèle de Kelvin,
- η_M : Viscosité dynamique du modèle de Maxwell,
- η_K : Viscosité dynamique du modèle de Kelvin,
- c : Cohésion, - φ : Angle de frottement,
- ψ : Angle de dilatance, - σ_t : Résistance en traction.

L'étude de ce type de lois nécessite de rappeler préalablement la théorie de l'élastoplasticité puis de définir le cadre de l'extension de celle-ci à l'ensemble des lois élasto-viscoplastiques. Le paragraphe suivant résume les principales notions de base régissant la théorie de l'élastoplasticité.

4 Composantes du tassement

Comme tous les autres matériaux, le sol se déforme lorsqu'on lui applique une charge. Selon les principes généraux de la mécanique des sols, la déformation d'un sol saturé est liée à la variation de la contrainte effective. Celle-ci peut être due à des chargements extérieurs mais aussi à des rabattements de nappe dans les massifs de sol.

En général, le tassement est dû à la compressibilité des sols, c'est-à-dire que son volume est réduit. Cette compressibilité est le résultat de :

- ❖ La compression du volume de l'air qui remplit les vides et provoque une déformation quasiment instantanée.
- ❖ L'évacuation de l'eau contenue dans les vides, elle produit la déformation la plus importante, le sol subit une diminution de volume correspond au volume d'eau expulsée.
- ❖ La compression du squelette solide, elle correspond à la déformation des grains qui s'arrangent entre eux de façon à occuper un volume plus réduit.

En conclusion, le tassement total final d'un sol a donc trois composantes, instantanée, primaire et secondaire, D'où la formule globale suivante :

$$S_t = S_p + S_s = S_i + S_c + S_s \quad (1.14)$$

Avec:

S_p : le tassement primaire; S_s : le tassement secondaire; S_i : le tassement immédiat; S_c : le tassement de consolidation primaire.

Le tassement immédiat est par définition indépendant du temps, tandis que les tassements de consolidation primaire et le tassement secondaire sont fonction du temps. De manière générale, le tassement immédiat est évalué sur la base de la théorie de l'élasticité. Le tassement de consolidation se manifeste dans les sols à grain fin avec un faible coefficient de perméabilité.

4.1 Tassement instantané

Ce type de tassement est également appelé tassement initial, immédiat ou de compression élastique. Il se produit immédiatement après l'application de la charge sur le sol. Dans la conception des fondations, ce tassement doit être pris en compte. L'équation qui exprime ce type de tassement est similaire à l'équation utilisée pour évaluer la déformation d'une colonne sous une charge axiale. Elle s'écrit :

$$S_i = \frac{2 \times q \times B}{E} (1 - \nu^2) \times I_s \quad (1.15)$$

Avec:

q : charge uniforme. ν : Coefficient de Poisson. E : module d'élasticité du sol.

B : Le diamètre ou la largeur de la fondation. I_s : Coefficient d'influence.

4.2 Tassement primaire

En général et pour les sols fins, les charges appliquées (σ) sont d'abord reprise intégralement par l'eau interstitielle, ce qui crée une surpression ($u = \sigma$). Progressivement et en fonction de la perméabilité du sol, il y'aura transmission de cette charge vers le squelette solide. C'est la consolidation primaire théorisée par Terzaghi. Le tassement correspondant est évalué par la méthode œdométrique et dont la formule est :

$$S_p = \frac{H_0}{1 + e_0} \left(C_s \log \frac{\sigma'_p}{\sigma'_{v0}} + C_c \log \frac{\sigma'_{vf}}{\sigma'_p} \right) \quad (1.16)$$

- Pour un sol normalement consolidé ($\sigma'_p = \sigma'_{v0}$), cette formule se simplifie en :

$$S_p = \frac{H_0}{1 + e_0} \left(C_c \log \frac{\sigma'_{vf}}{\sigma'_p} \right) \quad (1.17)$$

- Pour un sol surconsolidé chargé en dessous de la pression de préconsolidation ($\sigma'_p > \sigma'_{v0}$):

$$S_p = \frac{H_0}{1 + e_0} \left(C_s \log \frac{\sigma'_{vf}}{\sigma'_{v0}} \right) \quad (1.18)$$

Avec:

H_0 : l'épaisseur initiale de la couche de sol.

e_0 : l'indice des vides initial.

σ'_{v0} : Contrainte effective verticale initiale.

σ'_{vf} : Contrainte effective final ($\sigma'_{vf} = \sigma'_{v0} + \Delta\sigma'_v$).

H_0 : L'épaisseur initiale de la couche considérée.

C_c : l'indice de compression, C_s : indice de gonflement et σ'_p : la contrainte de préconsolidation

A des fins pédagogiques, un modèle analogique fut proposé (Figure 1.14) en associant un cylindre muni d'une ouverture et d'un piston relié à un ressort. L'ouverture du piston représente la perméabilité du sol.

4.3 Le tassement secondaire

La compression secondaire ou fluage se produit sous une contrainte effective constante (Figure 1.15) et sans modification de la pression interstitielle. Ceci est dû principalement à l'arrangement graduel des particules de l'argile pour obtenir une configuration plus stable (Principe de Le Chatelier) et aux changements viscoélastiques dans la couche d'eau adsorbée.

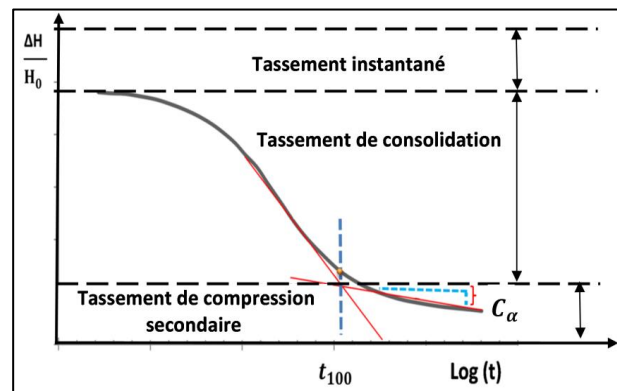



Figure 1.14 Phénomène de la consolidation primaire. Figure 1.15 Courbe de la consolidation primaire.

Buisman (1936) a probablement été le premier à proposer une loi de fluage pour l'argile après avoir observé que le tassement des sols meubles n'était pas entièrement expliqué par la théorie classique de la consolidation. La relation généralement adoptée pour lier le tassement secondaire S_s , dû au fluage, au temps t est :

$$S_s = \frac{H_0}{1 + e_0} \times c_\alpha \times \text{Log} \left(\frac{t}{t_0} \right) \quad (1.19)$$

Dans cette relation, H_0 , C_α et t_0 sont respectivement l'épaisseur de la couche de sol, le coefficient de compressibilité secondaire et le temps correspondant au temps de la fin de la consolidation primaire.

Le fluage des sols peut se composer de trois parties (Figure 1.16) :

- le fluage primaire (à vitesse de déformation décroissante $\dot{\epsilon} < 0$) ;
- le fluage secondaire (ou à vitesse constante $\dot{\epsilon} = 0$) ;
- le fluage tertiaire (à vitesse croissante $\dot{\epsilon} > 0$).

En général, le fluage volumétrique correspond au fluage primaire, c'est-à-dire qu'il est à vitesse décroissante et tend à se stabiliser. Le fluage déviatorique (cisaillement) peut ou ne pas se manifester sous les trois phases, selon la mobilisation de cisaillement. La rupture après fluage ne s'observe pas sur les argiles normalement consolidées et il n'y a pas de rupture "visqueuse" (Vuailat, 1980). Quand le fluage s'accélère, il se termine souvent par une rupture et c'est souvent sous une sollicitation déviatorique.

En raison de la complexité du phénomène de fluage et du grand nombre de facteurs qui l'affectent, plusieurs théories de fluage ont été développées pour décrire ce comportement pour une gamme de matériaux réels. Ces différentes théories se rejoignent toutes sur le fait qu'elles proposent une relation entre les paramètres d'état que sont les contraintes et les déformations et le paramètre temps. Ces relations peuvent être formulées symboliquement sous la forme :

$$\epsilon = f(\sigma, t) \text{ ou } \sigma = f(\epsilon, t) \quad (1.20)$$

4.4 Caractéristiques de consolidation et de fluage

4.4.1 Caractéristiques de consolidation

Les paramètres de compressibilité (pression de préconsolidation σ'_p , indice de compression C_c et indice de gonflement C_s) sont traditionnellement déterminés à partir d'essais œdométriques classiques à charge par paliers. Ces paramètres peuvent être influencés par la qualité des éprouvettes et des méthodes expérimentales utilisées, ainsi que par d'autres facteurs plus ou moins sensibles tels que la température, l'humidité, la composition chimique du fluide interstitiel ou la composition minéralogique du squelette. Ces paramètres peuvent être déterminés graphiquement sur la courbe représentant les variations de l'indice de vides en fonction des contraintes appliquées. Dans la plupart des cas, cette courbe, appelée courbe de compressibilité, est représentée dans un diagramme ($e, \log \sigma'$) proposé initialement par Casagrande (1936) et confirmé ensuite par la pratique. Les variations de l'indice de vide en fonction des contraintes effectives peuvent être représentées par une loi semi-logarithmique caractérisée par la relation suivante :

$$\Delta e = -C_x \times \Delta \log(\sigma') \quad (1.21)$$

- $C_x = C_s$ dans le domaine surconsolidé ($\sigma' < \sigma'_p$) ;
- $C_x = C_c$ dans le domaine normalement consolidé ($\sigma' > \sigma'_p$) (Figure 1.17).

La méthode de détermination des caractéristiques de compressibilité à partir des résultats d'essais œdométriques est réalisée selon les méthodes décrites par les laboratoires des ponts et chaussées (Magnan et al., 1985).

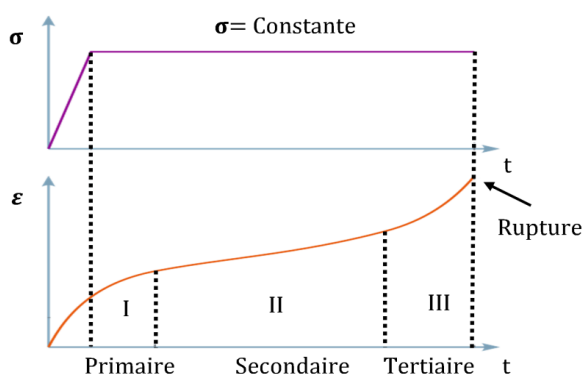


Figure 1.16 Phases d'évolution de fluage.

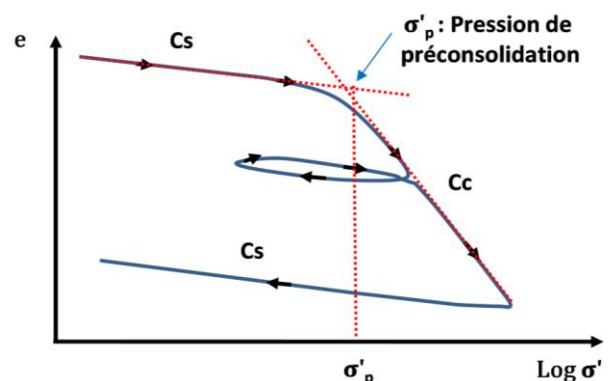


Figure 1.17 Courbe de la compressibilité

Par ailleurs, le comportement de consolidation des sols argileux est régi par la loi formulée par Terzaghi et qui exprime les variations du taux de dissipation de la surpression interstitielle par l'équation suivante :

$$\frac{\partial u}{\partial t} = C_v \frac{\partial^2 u}{\partial z^2} \quad (1.22)$$

Dans cette équation, C_v désigne le coefficient de consolidation du sol.

Dans l'équation de compressibilité œdométrique, le paramètre temps ne figure pas. C'est aussi le cas du tassement qui ne figure pas dans l'équation de consolidation de Terzaghi. Le couplage est en fait réalisé par des constructions graphiques proposées par Casagrande (1936) ou par Taylor (1942). Dans la première, la variation de l'indice des vides est représentée en fonction du logarithme du temps alors que dans la seconde, la variation de l'indice des vides est représentée en fonction de la racine carrée du temps. Ces constructions permettent d'estimer le temps de la fin de la consolidation primaire.

Dans le cas des argiles tendres, les méthodes d'essai du laboratoire des ponts et chaussées (LCPC) recommandent l'utilisation de la méthode de Taylor, dont le principe est illustré à la figure 1.18. Sur cette figure, la ligne D_1 correspond à la partie quasi linéaire du début de la courbe de décompte, elle coupe l'axe des y en un point d_c qui est le zéro corrigé (la lecture initiale ne sera pas prise en compte dans la construction graphique). La ligne D_2 est la ligne passant par le point d_c et ayant une pente 1,15 fois inférieure à celle de D_1 . Le point d'intersection de cette dernière avec la courbe de compressibilité donne le point, noté t_{90} , correspondant à 90% de consolidation primaire.




Figure 1.18 Méthode de Taylor (1942)

4.4.1.1 Corrélation sur les paramètres de compressibilité et consolidation

La durée importante des essais œdométriques a conduit les utilisateurs à chercher d'autres moyens rapides et moins chers pour accéder aux paramètres de compressibilité. Les techniques de corrélations représentent une solution, notamment si les paramètres utilisés sont de détermination rapide, comme la teneur en eau, les paramètres de plasticité, etc. Il existe de nombreuses corrélations proposées par divers auteurs. Le tableau 1.1 regroupe ceux que nous avons pu relever dans la littérature.

Ainsi, Singh et Noor (2012) ont proposé une corrélation entre l'indice de compression (C_c), la limite de liquidité et l'indice de plasticité. Le modèle basé sur une analyse de régression multiple a donné une erreur minimale (RME = 0,035) par rapport à celles de Skempton (RME = 0,131) et de

Terzaghi et Peck (RME = 0. 211). Yoon et al (2004) ont alors proposé des équations empiriques utilisant la teneur en eau naturelle, l'indice des vides initial, la limite de liquidité et l'indice de plasticité pour les sols argileux dans la zone côtière de Corée. Abbasi et al (2012) ont suggéré un modèle de corrélation entre les propriétés physiques et l'indice de compression (C_c) en utilisant un logiciel d'analyse de données statistiques (SPSS). Par ailleurs, les études sur l'indice de recompression (C_s) semblent être assez limitées (Nagaraj et Murthy, 1985; Nakase et al., 1987; Işık, 2009). Les recherches montrent que les paramètres physiques des sols ont un effet significatif sur les paramètres de compressibilité du sol. La première tentative pour prédire le coefficient de consolidation, C_v a été faite en 1985 par Carrier, il a compilé un ensemble de 70 résultats d'essais sur différents types de matériaux, afin de relier l'activité (ACT), l'indice de liquidité (IL) et l'indice de plasticité (I_p) des mêmes matériaux (Carrier, 1985). Raju et al. (1995) ont établi un certain nombre de corrélations entre le coefficient de consolidation (C_v) et l'indice des vides, la contrainte appliquée et la limite de liquidité du matériau. Ces travaux lui ont permis, ainsi qu'à Nagaraj et al. (2012), de proposer des relations élémentaires entre les propriétés mécaniques des sols modifiés normalement consolidés et les limites d'Atterberg. Les auteurs ont constaté que l'indice de retrait (I_s) a une meilleure corrélation avec les caractéristiques de compressibilité. Une corrélation a été trouvée entre la texture du sol et la teneur en matière organique du sol. En effet, la matière organique est positivement corrélée avec la teneur en argile et inversement avec la teneur en sable (Van veen et Paul, 1981). Ces modèles reposent essentiellement sur les mêmes approches.

4.4.2 Caractéristiques du fluage

Le coefficient de compressibilité C_α est souvent rencontré quand il s'agit d'exprimer la relation du fluage. Or cette relation s'exprime par la variation de l'indice des vides ou par le tassement relatif. Pour éviter toute confusion, un coefficient $C_{\alpha e}$, lié à C_α , est introduit et la relation proposée par Buisman (1936) peut finalement s'écrire sous la forme :

$$\Delta e = C_{\alpha e} \times \Delta(\log t) \quad (1. 23)$$

Dans cette relation, Δe est la variation de l'indice des vides et $\Delta(\log t)$ est la variation du logarithme du temps entre le début du chargement et la fin du tassement. La relation précédente peut être écrite sous la forme :

$$\varepsilon = \frac{\Delta h}{h_0} = C_\alpha \cdot \Delta(\log t) \quad (1. 24)$$

Avec:

$$C_\alpha = \frac{C_{\alpha e}}{1 + e_0} \quad (1. 25)$$

ε , Δh , h_0 et e_0 , sont respectivement la déformation verticale, le tassement, l'épaisseur initiale de la couche de sol et l'indice de vides initial.

Tableau 1.1 Corrélation sur les paramètres de compressibilité et consolidation

Paramètres	Equations	Auteurs
Corrélation pour C_c		
LL	$C_c = 0.007 \times (LL - 7)$	Skempton et Jones (1944)
	$C_c = 0.009 \times (LL - 10)$	Terzaghi et al. (1996)
	$C_c = 0.0045 \times (LL - 2.769)$	Güllü (2016)
	$C_c = 0.009 \times (LL - 2)$	Thinh et al.(2017)
w_n	$C_c = 0.00553 \times w_n + 0.05321$	Güllü (2016)
e₀	$C_c = 0.08358 \times e_0 + 0.12739$	Güllü (2016)
	$C_c = 0.156 \times e_0 + 0.0107$	Onyejekwe et al. (2015)
LL, G_s	$C_c = 0.2343 \times LL \times G_s$	Nagaraj et al. (1990)
	$C_c = 0.2926 \times LL \times G_s$	Park et Lee (2011)
w_n, LL	$C_c = 0.009 \times w_n + 0.005 \times LL$	Koppula (1981)
	$C_c = 0.009 \times w_n + 0.002 \times LL - 0.1$	Azzouz et al. (1976)
e₀, w_n	$C_c = 0.4 \times (e_0 + 0.001 \times w_n - 0.25)$	Azzouz et al. (1976)
LL, PI	$C_c = 0.002 \times LL + 0.0025 \times PI - 0.005$	Singh et Noor (2012)
e₀, LL	$C_s = 0.126 \times (e_0 + 0.003 \times LL - 0.06)$	Azzouz et al.(1976)
	$C_c = -0.156 + 0.411 \times e_0 + 0.00058 \times LL$	Al-Khafaji et Andersland (1992)
	$C_c = -0.023 + 0.271 \times e_0 + 0.001 \times LL$	Ahadian et al. (2008)
	$C_c = 0.173 \times (1 + e_0) \times (\ln(LL) - 3.01)$	McCabe et al. (2014)
	$C_c = 0.004483 \times LL + 0.028871 \times e_0 - 0.03029)$	Güllü (2016)
G_s, e₀	$C_c = 0.141 \times G_s^{1.2} \left[\frac{(1 + e_0)}{G_s} \right]^{2.38}$	Rendon Herrero (1983)
e₀, w_n, LL	$C_c = 0.37 \times (e_0 + 0.003 \times LL + 0.0004 \times w_n - 0.33)$	Azzouz et al. (1976)
	$C_c = -0.404 + 0.341 \times e_0 + 0.004 \times LL + 0.006 \times w_n)$	Yoon et al. (2004)
Corrélation pour C_s		
IP	$C_s = 0.00194 \times (IP - 4.6)$	Nakase et al. (1987)
LL, G_s	$C_s = 0.0463 \times \left[\frac{LL}{100} \right] \times G_s$	Nagaraj et Murty (1985)
	$C_s = 0.000463 \times LL \times G_s^2$	Nagaraj et Murthy (1985)
w_n, LL	$C_s = 0.03 \times w_n + 0.0006 \times LL + 0.004$	Azzouz et al.(1976)
e₀, w_n	$C_s = 0.142 \times (e_0 - 0.0009 \times w_n + 0.006)$	Azzouz et al.(1976)
e₀, LL, w_n	$C_s = 0.135 \times (e_0 + 0.01 \times LL - 0.002 \times w_n - 0.06)$	Azzouz et al.(1976)
w_n, γ_d, e₀	$C_s = -0.000319 \times w_n - 0.027277 \times \gamma_d + 0.064019 \times e_0 + 0.037$	Işık (2009)
Corrélation pour C_v		
LL	$C_v = 4258 \times LL^{-1.75}$	Al-Taie et Al- Ameri (2011)
	$C_v = -4 \times 10^{-9} \times LL + 4 \times 10^{-7}$	Devi et al. (2015)
IP	$C_v = 7.7525 \times IP^{-3.1025}$	Solanki et Desai (2008)
	$C_v = -4 \times 10^{-7} \times \log (IP) + 6 \times 10^{-7}$	Devi et al. (2015)
	$C_v = -0.0183 \times IP + 0.6155$	Ng et al. (2018)
LL, IP	$C_v = 0.451 + 0.011 \times LL - 0.0367 \times PI$	Ng et al. (2018)
LL, σ'_v	$C_v = LL + LL^2 \times (1.23 - 0.276 \times \log \sigma'_v) \times \sigma'_v^{-0.353} \times 10^{-3}$	Raju et al. (1995)

De nombreux travaux ont été réalisés sur le coefficient C_a . Pour des argiles intactes, Thompson et Palmer (1951) notent que ce coefficient dépend de la contrainte appliquée, les valeurs maximales

sont obtenues pour des contraintes proches de la contrainte de préconsolidation. Newland et Allely (1960) constatent que le coefficient C_α est globalement indépendant de la pression de préconsolidation. Davies et Dennison (1975), après une étude sur des argiles remaniées, ont conclu que C_α est un paramètre constant pour une argile donnée pour des valeurs des contraintes effectives excédant la pression de préconsolidation apparente. Elhusein (2001), Fodil et al. (1997) notent que pour une argile non remaniée, le coefficient C_α augmente avec la contrainte effective verticale appliquée mais cette croissance est peu significative au-delà de la contrainte de préconsolidation. Magnan et al. (2001), suite à des essais œdométriques sur des argiles intactes provenant de deux sites différents, concluent que C_α augmente pour des contraintes inférieures à la contrainte de préconsolidation pour décroître ensuite. Les travaux de Yin et Karstunen (2011) et Yin et al. (2017), les mènent à conclure que le coefficient C_α n'est pas constant. Ils attribuent cette conclusion à la dégradation des liaisons inter-particulaires du squelette solide due au fluage. Ils voient que ce coefficient devrait être lié à la microstructure des argiles (Yin et al., 2014, 2017; Yin et Chang, 2009). C'est la conclusion à laquelle aboutit Fabre (Fabre, 2005). Mesri et Godlewski (1977), après des essais sur des argiles molles d'origines diverses, montrent que le coefficient C_α peut être relié à l'indice de compression C_c . Le rapport C_α / C_c varie entre 0,02 et 0,06. Ce paragraphe montre que le coefficient de compression secondaire C_α est un paramètre difficile à cerner. Il dépend de nombreux paramètres dont l'histoire du chargement, la contrainte de préconsolidation, la composition minéralogique, etc. C'est pour cette raison que certains chercheurs ont proposé de relier ce coefficient à des paramètres physicochimiques des sols facilement mesurables.

4.4.2.1 Corrélation sur le coefficient de compression secondaire

Etablir des corrélations entre certains paramètres de sols difficilement accessibles et d'autres facteurs facilement mesurables a été testée dans d'autres aspects de la géotechnique (Djedid et al., 2001, Güllü et al., 2016). La validité de ces modèles reste discutable. Pour le coefficient de compression secondaire C_α , Tsukada et Yasuhara (1995) ont proposé la relation suivante reliant ce paramètre à l'indice des vides:

$$C_\alpha = 0,0145 \times e_0^{1,555} \quad (1.26)$$

Yin et al (2010) concluent que pour une argile molle intacte, l'expression du coefficient C_α devrait prendre en compte au moins le degré de sur-consolidation, la densité ou l'indice des vides et la structure. Cette dernière est un obstacle pour les ingénieurs car elle est difficilement caractérisable par des paramètres utilisables dans leurs travaux quotidiens.

Anagnostopoulos et Grammatikopoulos (2011) ont proposé un modèle reliant l'indice de compression C_c , la limite de liquidité W_L , la limite de plasticité W_P et la teneur en eau naturelle W_n au coefficient C_α comme écrit ci-dessous:

$$C_\alpha = C_c \times W_L \times W_P^{-1.571} \times W_n \quad (1.27)$$

S'appuyant sur une base de données provenant d'essais œdométriques, Jesmani et al. (2012) ont mis au point un modèle reliant le coefficient C_α à l'indice de compression C_c et à l'indice de plasticité I_p :

$$C_\alpha = C_c \times 10^{(0.331 \log(I_p) - 1.955)} \quad (1.28)$$

Ce modèle est supposé valable pour des indices de plasticité supérieurs à 70%.

Les deux premiers modèles ont été établis en utilisant les régressions simples alors que le troisième modèle a été mis au point à l'aide des régressions multiples.

Les régressions simples ou multiples présentent l'avantage d'être simples dans l'utilisation. Néanmoins, elles donnent souvent des coefficients de corrélations très faibles si des discontinuités sont présentes dans la distribution des mesures comme la présence de plusieurs sous-nuages de mesures nettement dissociés.

4.5 Les différentes méthodes d'estimation des tassements

Les estimations de tassement appliquées aux projets d'infrastructure linéaire ou de construction peuvent produire en termes d'amplitude, des résultats très différents selon l'approche utilisée, méthode pressiométrique ou œdométrique, calcul par éléments finis ou utilisation de formules simplifiée, etc. Face à ce type de problème, les géotechniciens se sont dirigés vers des modèles pragmatiques basés sur le comportement réel du sol en organisant des campagnes de suivies s'étalant sur de longues périodes. Ces mesures, qui peuvent être réalisées dans le cadre d'une approche observationnelle au sens de l'eurocode, permettent d'affiner les calculs théoriques. La mise en œuvre de ces modèles observationnels sera décrite dans les paragraphes suivants.

4.5.1 Méthode Asaoka

La méthode d'Asaoka (1978) a été énoncée initialement pour prévoir le tassement maximum dû à la consolidation des sols. Cette méthode est basée sur l'analyse des tassements observés à des intervalles de temps réguliers (Figure 1.19). La construction consiste à dresser sur un graphique, le tassement observé à un instant $t+\Delta t$ en fonction du tassement observé à l'instant t (Figure 1.20). Sur ce graphique, Magnan et Deroy (Magnan et Deroy, 1980) ont montré que si le sol est doué de fluage, deux droites peuvent être observées, une première droite (A) qui correspond à la consolidation primaire et une seconde droite (B) qui correspond à la consolidation secondaire. Le tassement dû au fluage est donné par la rencontre de la droite B avec la bissectrice du plan du graphique.

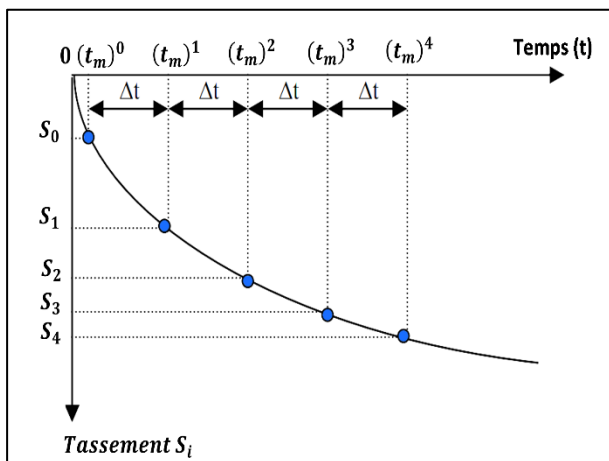


Figure 1.19 Discretisation de la courbe de consolidation

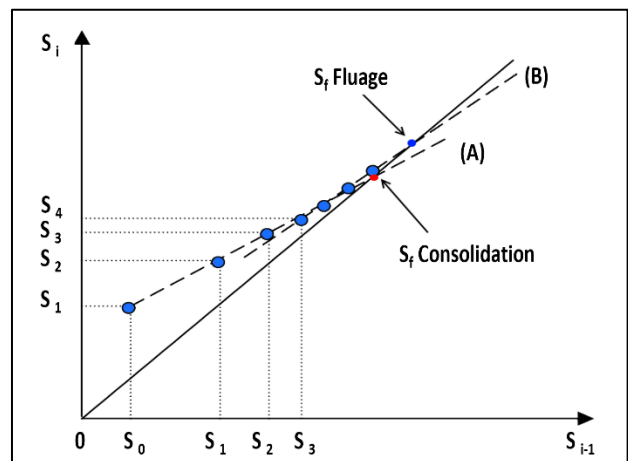


Figure 1.20 Construction d'Asaoka

L'efficacité de cette méthode repose essentiellement sur le choix de l'échelle du temps et de l'incrément Δt (Edil et al. 1991).

4.5.2 Méthode de Recordon

Le principe de la méthode de Recordon consiste à résoudre analytiquement l'équation de la diffusion de la surpression interstitielle en fonction de la profondeur et du temps. La présente équation, qui a été déjà mentionnée précédemment, s'écrit :

$$\frac{\partial u(t,z)}{\partial t} = Cv \frac{\partial^2 u(t,z)}{\partial z^2} \tag{1.29}$$

Ainsi, la solution exacte de cette équation aux dérivées partielles établie par Terzaghi s'écrit comme une série entière en fonction du degré de consolidation, ce qui signifie que le premier terme est traduit en termes de déplacements, sans prendre en compte les autres termes (Recordon, 1988) :

$$s(t) = s_{\infty} (1 - B e^{-Ct}) \tag{1.30}$$

Cette méthode revient donc à considérer que le tassement suit une loi exponentielle, où :

s_{∞} est le tassement final, B est un coefficient permettant la correspondance entre le début de la consolidation et le début des mesures et C est un coefficient proportionnel au coefficient de consolidation verticale. Ainsi, cette méthode permet de déterminer non seulement le tassement final du sol mais aussi le temps correspondant à des degrés de consolidation divers. La figure 1.21 présente la représentation graphique de la méthode de Recordon pour différentes valeurs des coefficients B et C.

4.5.3 Méthode d'Al-Shamrani

En ce qui concerne les valeurs de déplacement δ_i mesurés à des temps t_i , la méthode d'Al-Shamrani consiste à représenter les valeurs (t_i / s_i) en fonction du temps et à trouver la ligne qui passe au mieux par ces points dans le sens des moindres carrés. Cette méthode revient à considérer que le tassement suit une loi hyperbolique:

$$\frac{t}{s} = A t + B \tag{1.31}$$

Ce qui revient à écrire :

$$s(t) = \frac{t}{A t + B} \tag{1.32}$$

Le tassement final est donné par l'inverse du coefficient A, le pourcentage du tassement primaire étant d'environ de 82 % de cette valeur (Al-Shamrani, 2004). La figure 1.22 montre la représentation de cette méthode.

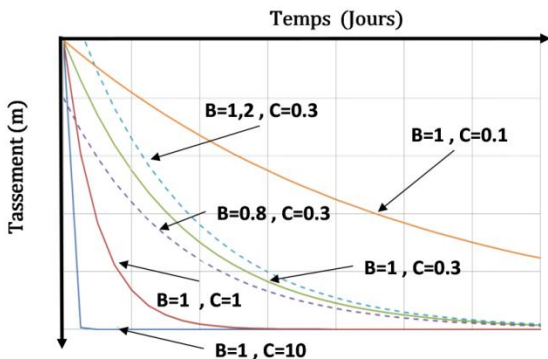


Figure 1.21 Influence des coefficients B et C sur la solution de Recordon.




Figure 1.22 Application de la méthode d'Al-Shamrani.

4.5.4 Modèles mathématiques

4.5.4.1 Modèle hyperbolique

Le modèle hyperbolique est fondé sur un système d'équations aux dérivées partielles de type hyperbolique qui décrit les variations numériques du tassement au cours du temps. Ce modèle a été largement utilisé avec succès pour de nombreuses applications, Cependant, dans les applications avec un temps très long, l'exécution devient difficile et complexe (Ling et al. 1998). Le modèle s'exprime par la relation suivante :

$$s_t = s_0 + \frac{(t - t_0)}{[p + q(t - t_0)]} \quad (1.33)$$

t_0 représente le temps où s'opère le point d'inflexion, s_0 le tassement à l'instant t_0 , s_t le tassement à un moment donné, p , q sont des constantes.

4.5.4.2 Modèle exponentiel

Pour décrire la relation entre le tassement et le temps, Recordon (1988) a proposé une fonction exponentielle continue, basée sur la théorie de Terzaghi qui suppose que la consolidation se produit seulement dans une dimension. Ce modèle a souvent donné satisfaction pour les sols au-delà de 50% de consolidation (Zhou et al. 2011). Le modèle s'exprime par l'équation suivante :

$$s_t = (s_\infty + s_\infty \beta \exp(-\gamma t)) \quad (1.34)$$

S_t correspond au tassement à l'instant t ; S_∞ le tassement final; β , γ sont des constantes calculées à l'aide de l'ajustement.

4.5.4.3 Modèle Logistique

Cherchant un modèle d'évolution non exponentielle comportant un paramètre pour amortir et contrôler la vitesse du tassement à long terme, Changming et al. (2004) ont proposés un modèle basé sur la régression logistique. Ce modèle s'écrit :

$$s_t = \frac{S_\infty}{1 + ae^{-bt}} \quad (1.35)$$

C'est le tassement final S_∞ qui servira de paramètre de contrôle de la vitesse, s_t étant le tassement à l'instant t . Les constantes a , b sont à déterminer par ajustement.

4.5.4.4 Modèle de Gompertz

La fonction Gompertz est un cas particulier de la fonction logistique généralisée (Chuang et Song-yu, 2005). Cette fonction permet d'assurer une souplesse de façon de tenir compte de la croissance rapide du tassement au début de la consolidation tout en présentant une asymptote horizontale à la fin de la consolidation. Le modèle est exprimé sous la forme suivante:

$$s_t = s_\infty \exp[-m \cdot \exp(-nt)] \quad (1.36)$$

S_∞ : est le tassement final, S_t : le tassement à un moment donné t et m , n sont des constants

4.5.4.5 Modèle de Usher

Le modèle d'Usher est modèle mathématique permettant de décrire et de prévoir l'évolution du tassement. La fonction a été paramétrée pour qu'elle apparaisse sous deux formes différentes selon la vitesse de la variation du tassement. Si $b = 1$, ce modèle devient le modèle logistique et lorsque b tend vers 0, il se transformera en modèle de Gompertz. Le modèle s'écrit:

$$s_t = \frac{S_\infty}{[1 + a \cdot \exp(-c \cdot t)]^{\frac{1}{b}}} \quad (1.37)$$

S_t est le tassement à l'instant t (mm), S_∞ est le tassement final (mm). Les constantes a , b et c sont calculées à l'aide d'un algorithme d'ajustement.

5 Conclusion

Ce chapitre à caractère bibliographique décrit les aspects théoriques et expérimentaux du fluage des sols argileux. Il donne un aperçu historique sur les études qui ont concerné ce phénomène en insistant sur le coefficient de compression C_α et sur la séparation entre consolidation primaire et consolidation secondaire. Il en découle de cette synthèse que le fluage est un phénomène complexe, car il s'agit d'un problème qui se manifeste d'abord comme un comportement de nature visqueuse mais qui peut évoluer vers d'autres phénomènes (fluage secondaire et tertiaire, rupture, etc.).

La revue de la théorie du fluage et des modèles rhéologiques sert surtout à exposer surtout les outils dont disposent les chercheurs pour approcher ce phénomène. Ce chapitre expose aussi les modèles observationnels de prédiction du tassement à long terme basés sur les observations réelles (Asaoka, Recordon, Al Shamrani) et ceux basés les formules mathématiques (exponentiel, logistic, Gompertz et Usher).

Une revue détaillée sur les différents paramètres influençant le comportement de fluage a été exposé, focalisée principalement sur les paramètres facilement mesurables. Les constatations établies dans cette partie nous ont permis de mettre en exergue les paramètres les plus influant sur le fluage des sols. Il en ressort que l'histoire du chargement, la contrainte de préconsolidation, la composition minéralogique influent énormément sur le coefficient de compression secondaire C_α . Cette revue a été complétée par les modèles issues de corrélations et qui permettent d'estimer les paramètres de consolidation des sols argileux à l'aide des paramètres géotechniques facilement mesurables au laboratoire.

Le chapitre suivant portera sur des éléments complémentaires sur ce sujet : les lois de comportement et les techniques d'analyse directe et inverse sur le phénomène étudié.

CHAPITRE 2

ANALYSE DIRECTE ET INVERSE EN GEOTECHNIQUE

1 Introduction

Pour déterminer une loi comportement, il s'agit de trouver des relations entre la contrainte et la déformation au cours d'une sollicitation donnée. En règle générale, l'élaboration d'une loi de comportement dépend de plusieurs phénomènes liés à la nature du sol tels que la compressibilité, la perméabilité, la consolidation et le fluage. Elle s'appuie également sur les principes de la mécanique des milieux continus et de la thermodynamique, comme les principes de continuité, de conservation, de déterminisme, etc. En raison de leur structure granulaire, poreuse ou polycristalline, le comportement des sols, en particulier celui des argiles, est difficile à modéliser, surtout quand il s'agit du fluage. Proposer des lois de comportement des sols qui prennent en compte ce phénomène serait de la plus grande utilité pour les ingénieurs géotechniciens.

C'est pour ces raisons que ce chapitre est proposé. Il passe en revue les divers modèles utilisés dans la pratique pour simuler le comportement des sols puis décrits sommairement certains codes de calculs dont ces modèles de comportement des sols sont implémentés. A la fin, c'est ce sont les techniques de l'analyse inverse qui sont exposées.

2 Principaux types de lois de comportement

Le comportement des matériaux est simulé à l'aide des modèles rhéologiques. En général, les modèles qui peuvent représenter le comportement des matériaux nécessitent de nombreux paramètres, qui sont parfois difficiles à déterminer. Dans ce qui suit, une description des principaux types de lois comportement sera donnée.

2.1 Comportement élastique linéaire




Figure 2.1 Loi de comportement élastique linéaire

Lorsque la courbe contrainte-déformation est la même pendant les processus de chargement et de déchargement, le comportement du matériau est considéré comme élastique. Si la relation entre le tenseur des contraintes et celui des déformations est linéaire, le comportement du matériau est dit élastique linéaire. Dans le cas d'un essai de compression ou de traction simple, la relation contraintes-déformations est caractérisée par deux paramètres : un module élastique axial, le module de Young E et le coefficient de Poisson ν . Dans le cas d'un cisaillement simple, le module d'Young est remplacé par le module de cisaillement G (Figure 2.1).

Cependant, cette loi de comportement ne peut représenter le comportement réel du sol, même sous les faibles déformations, Dans le but d'écrire un comportement plus proche de la réalité, des lois plastiques ont été proposées.

2.2 Comportement élastoplastique

L'existence de déformations plastiques ou permanentes a été mise en évidence par Coulomb en 1784 (Mestat, 1993). Les essais réalisés montrent que la plage de réversibilité des déformations, ou plage d'élasticité, est relativement limitée. Sous un certain degré de contrainte, une déformation irréversible ou plastique se produit. Ce type de comportement macroscopique est caractéristique de

la plupart des solides (métaux, bétons, sols et roches). Au niveau microscopique, l'origine de la déformation permanente dépend du matériau. Dans le cas des sols, elles proviennent de la modification de l'assemblage des particules solides.

Dans les formulations, la déformation totale est généralement divisée en deux composantes comme écrit ci-dessous :

$$\varepsilon = \varepsilon^e + \varepsilon^p \quad (2.1)$$

Avec : ε la déformation totale, ε^e la déformation élastique et ε^p la déformation plastique.

Le comportement plastique ou élastoplastique est basé sur quatre notions fondamentales, à savoir la surface de charge, la règle d'écrouissage, la règle d'écoulement et le critère de rupture. Cependant il n'inclut aucun effet du vieillissement et de viscosité du matériau.

2.2.1 Comportement élastique linéaire parfaitement plastique

Le modèle le plus simple de cette famille est le modèle élastique linéaire parfaitement plastique, utilisé à l'origine pour décrire de manière approchée, le comportement des métaux. Cependant, l'existence d'un palier d'écoulement sur la courbe contraintes-déformations, a suggéré d'étendre ce modèle aux bétons, aux sols et aux roches. Ce modèle approche mieux le comportement des sols que le modèle élastique linéaire puisqu'il permet d'analyser les ruptures constatées sur les ouvrages.

Le critère de rupture de Mohr-Coulomb représente l'enveloppe linéaire qui est obtenue par le rapport entre la contrainte de cisaillement et la contrainte normale. A partir de ce critère, il est possible de construire une loi de comportement élastique parfaitement plastique, caractérisée par une élasticité linéaire (E, ν) et un seuil de plasticité, défini par la cohésion c' , l'angle de frottement interne ϕ' , en plus de l'état initial (Figure 2.2). Ce modèle est le plus utilisé dans la pratique de l'ingénierie pour décrire de manière approchée le comportement des sols pulvérulents (sable et gravier) et le comportement drainé, à long terme des sols fins saturés (limon et argile). Le critère de rupture de Mohr-Coulomb est représenté dans le plan des contraintes de Mohr (contrainte effective normale σ' et contrainte tangentielle τ), par l'équation suivante :

$$\tau = \sigma' \times \tan\phi' + c \quad (2.2)$$

En termes de contraintes effectives principales (σ_1', σ_3') il s'écrit :

$$\sigma_1' - \sigma_3' = (\sigma_1' + \sigma_3') \sin\phi' - 2c' \cos\phi' \quad (2.3)$$

σ_1, σ_3 : contraintes effectives principales majeure et mineure, ϕ' , angle de frottement interne effective interne, c' cohésion effective.




Figure 2.2 Loi de comportement élastique linéaire parfaitement plastique de Mohr-Coulomb

Pour déterminer les paramètres du modèle, il faut au moins deux essais triaxiaux à des pressions de confinement différentes. Le niveau de charge F (σ_{ij}) s'exprime comme suit :

$$F(\sigma_{ij}') = (\sigma_1' - \sigma_3') - (\sigma_1' + \sigma_3') \sin\varphi' - 2c' \cos\varphi' = 0 \quad (2.4)$$

Les essais de laboratoire ont montré que ce modèle reste encore imparfait pour décrire complètement le comportement des sols. Il ne rend pas compte du phénomène d'écroûissage.

2.2.2 Comportement élastoplastique avec écroûissage

Dans cette grande famille, les lois sont basées sur fait que le sol subit des déformations plastiques au cours de la sollicitation avant la rupture. Les plastifications peuvent être de deux natures, elles sont soit liées au cisaillement ce qui peut conduire à la rupture du sol soit liées à la compression. Un comportement élastoplastique avec écroûissage permet de mieux décrire les étapes intermédiaires, observées en laboratoire, entre l'apparition des premières déformations irréversibles et le moment de la rupture. Mathématiquement, l'écroûissage entraîne une modification de la surface de charge dans l'espace des contraintes. Le type d'écroûissage peut, par ailleurs, être modifié par des trajets de chargements complexes ou par le vieillissement du matériau. De même, il peut être linéaire ou non-linéaire.

2.2.2.1 Comportement élastoplastique avec écroûissage linéaire

Ce comportement consiste à faire l'hypothèse d'un domaine purement élastique avant d'atteindre la plasticité. Ces deux domaines sont caractérisés par deux modules E_1 et E_2 , le premier modélise le comportement élastique et le second modélise le comportement plastique (Figure 2.3). Cette approche donne des résultats satisfaisants si le niveau de déformation est totalement dans le domaine élastique ou dans le domaine plastique. En revanche, la question du choix du module à prendre en compte se pose dans le cas où le niveau des déformations se situe dans la zone de transition. Une estimation fiable ne peut être obtenue avec cette approche. Il est nécessaire, pour tenir compte de cette zone de transition, de tenir compte du fait que les sols ont un comportement non linéaire, même à des niveaux de contrainte bien inférieurs à leur résistance (Thépot, 2004).




Figure 2.3 Capacité des lois à représenter l'évolution du module avec la déformation

2.2.2.2 Comportement élastoplastique avec écroûissage non linéaire

Les essais mécaniques en géotechnique ont montré que le module de déformation diminue lorsque la déformation augmente. Par conséquent, la rigidité du sol ne peut pas être modélisée par une ou deux valeurs uniques du module de déformation. La validation expérimentale pour le

comportement non-linéaire a été faite par Prager (1955), il a remarqué que lorsque la vitesse de déformation est quasi-statiques (traditionnellement comprises entre 4×10^{-4} et $5 \times 10^{-4} \text{ s}^{-1}$), la limite d'écoulement augmente progressivement. Afin de limiter le bruit sur les champs de déformation, le comportement élastoplastique avec écrouissage non-linéaire est recommandé. Ce comportement est identifié pour des déformations plastiques faibles de l'ordre de 2% maximum et une vitesse lente.

2.3 Comportement élastique viscoplastique

La théorie de la viscoplasticité décrit l'écoulement causé par le fluage du matériau, qui dépend essentiellement du temps. Ce comportement vise à décrire la relation entre le tenseur des vitesses de déformations viscoplastiques $\dot{\epsilon}^{vp}$ et le tenseur des contraintes σ dans le plus large domaine possible.




Figure 2.4 Domaines de comportement de la loi élasto-viscoplastique.

Les surfaces d'écoulement visqueux peuvent être représentées dans le plan déviatoriques (Figure 2.4). Contrairement à la plasticité indépendante du temps, il n'existe pas de relation de cohérence en viscoplasticité : la contrainte d'écoulement n'est pas nécessairement située sur la frontière du domaine élastique. L'écart entre la surface d'écoulement et la surface du domaine élastique est entièrement contrôlée par la contrainte visqueuse σ^* suivant la relation 2.5 :

$$\sigma^* = 2 \times (\sigma_{eq} - Y) \tag{2.5}$$

Avec : σ_{eq} : la contrainte équivalente et Y: La taille du domaine d'élasticité.

Le développement de ces lois de comportement (ou modèles rhéologiques) se fonde non seulement sur les schémas théoriques de la mécanique des milieux continus (élasticité, plasticité, viscosité et leurs combinaisons), mais aussi sur les résultats expérimentaux en laboratoire et in situ. Ainsi, en fonction des principales constatations expérimentales, des lois de plus en plus complexes ont été proposées pour rendre de tous les phénomènes observés. Dans la section suivante, une présentation des modèles plus réalistes à plusieurs niveaux, basés sur les propriétés physiques et mécaniques du sol.

3 Modèles et surfaces de charges adaptées aux sols fins

3.1 Modèles Cam-clay et Cam-clay modifié pour l'argile reconstituée

L'observation au laboratoire de l'argile reconstituée avec l'essai de consolidation isotrope et l'essai triaxial où $\sigma'_1 = \sigma'_3$ a permis de construire les modèles Cam-Clay (original et modifié), (Roscoe et al., 1963; Roscoe et Burland, 1968; Schofield et Wroth, 1968). Ces modèles sont de types élastoplastique avec écrouissage, développés dans le plan de contrainte moyenne (p') et contrainte déviatorique (q'), avec :

$$p' = \frac{(\sigma'_1 + 2\sigma'_3)}{3} \tag{2.6}$$

$$q' = (\sigma'_1 - \sigma'_3) \tag{2.7}$$

En effet, les travaux de l'université de Cambridge et de l'université Laval à Québec, Tavenas et Leroueil (1979), ont permis de préciser la forme de la surface de charge, ou courbe d'état limite dans le plan (p' , q). Les versions modifiées et révisées de ce modèle sont basées sur les concepts d'état limite et d'état critique (Figure 2.5). Ainsi, la forme de l'enveloppe de l'état limite de la loi Cam-Clay modifiée est adaptée aux sols remaniés sous consolidation isotrope, l'axe de symétrie de l'ellipse est sur l'axe p' (Shahanguian, 1981). La surface de charge est exprimée dans le plan (p' , q) selon la version du modèle par les formules (2.8) et (2.9) données ci-après :

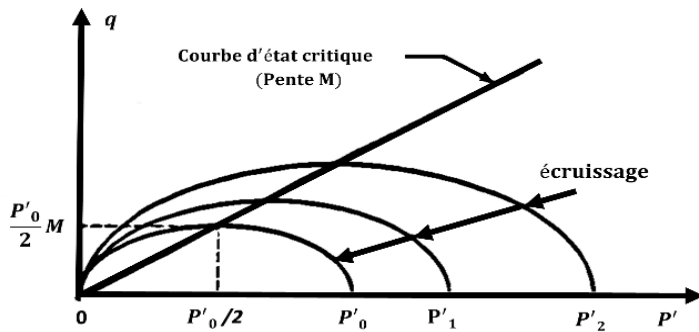


Figure 2.5 Modèles Cam-Clay original et Cam-Clay modifié

p' et q ont été définies auparavant. M est la pente de la courbe du critère de rupture ou courbe d'état critique alors que p'_0 est la contrainte moyenne initiale.

Pour la contrainte moyenne p'_0 , il s'agit de l'intersection de la surface de charge avec l'axe de compression isotrope. p'_0 définit la limite du domaine élastique actuelle et permet de faire évoluer la surface de charge.

Cam-clay original;
$$F(p', q) = \left(\frac{q}{M'p} \right) + \ln p' - \ln p'_0 = 0 \quad (2.8)$$

Cam-clay modifiée:
$$F(p', q) = \left(\frac{q}{M'p} \right)^2 + p' - p'_0 = 0 \quad (2.9)$$

3.2 Modèles pour les argiles naturelles

Les modèles Cam-Clay ont démontré leur pertinence dans la modélisation du comportement d'une argile reconstituée en laboratoire, isotrope et normalement consolidée ou légèrement surconsolidée. Par contre, ces modèles n'ont pas permis de modéliser le comportement des sols naturels. Ce phénomène est probablement dû à l'anisotropie des sols naturels, due à la façon dont les couches de sol se sont déposées dans le passé. Le sol est caractérisé par un coefficient de pression des terres au repos K_0 , exprimé par :

σ'_h : contrainte effective horizontale ;
$$K_0 = \frac{\sigma'_h}{\sigma'_v} \quad (2.10)$$

 σ'_v : contrainte effective verticale.

Afin de construire un modèle apte à approcher le comportement des sols naturels, plusieurs études basées sur des essais en laboratoire ont été menées pour trouver la forme de la surface de charge. Pour déterminer celle-ci, deux méthodes ont été proposées. L'une consiste à effectuer des essais de cisaillement anisotrope qui rayonnent autour d'un point considéré comme étant l'état des contraintes in situ (Crooks et Graham, 1976; Graham et Harmon, 1983) (Figure 2.6.a). L'autre méthode nécessite de combiner un essai œdométrique pour déterminer la pression de préconsolidation, des essais triaxiaux non drainés, avec des pressions de confinement inférieures à 0,5 fois la pression de préconsolidation, et des essais de consolidation anisotrope σ_3/σ_1 sans reconsolidation à l'état de contrainte en place (Leroueil et Tavenas, 1977; Tavenas et Leroueil, 1979) (Figure 2.6.b).

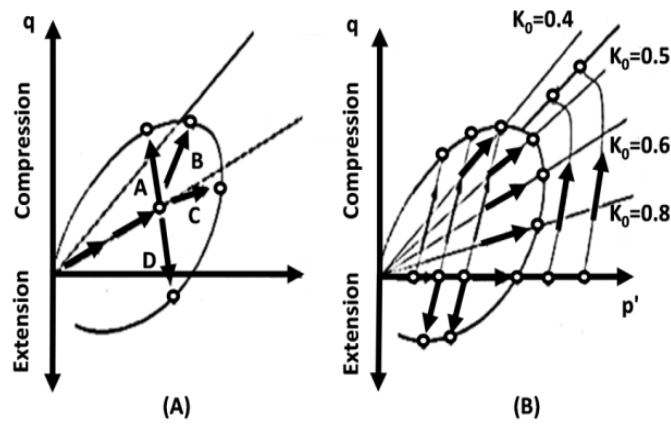


Figure 2.6 Méthode de détermination de la surface de charge.

Dans le cadre des deux méthodes décrites ci-dessus, plusieurs études ont été réalisées pour déterminer la surface de charge des sols naturels (Figure 2.7).

Plusieurs auteurs ont réalisé des études concernant ce point et on aboutit au fait que, comme le montre la figure 2.8 ci-dessous, la surface de charge n'est pas symétrique autour de l'axe de consolidation isotrope (axe S'). Cependant, les points expérimentaux se localisent presque symétriquement autour de l'axe de consolidation anisotrope (axe K_0), qui reflète l'historique du chargement du sol. Ces conditions sont probablement régies par l'état initial des contraintes en place et par la contrainte effective de préconsolidation σ'_p , qui est un paramètre reflétant l'historique du chargement du sol.

En effet, les surfaces de charge d'argile naturelle illustrées sur les figures (2.7 et 2.8) ont conduit les rhéologues à trouver des modèles mieux à même d'exprimer le comportement des sols naturels en prenant en compte leur anisotropie. Dans ce qui suit, nous présentons trois modèles de cette famille, le modèle de Larsson, de Mélanie et de Anpetal.




Figure 2.7 Surfaces de charge de différentes argiles naturelles Mestat (1993).

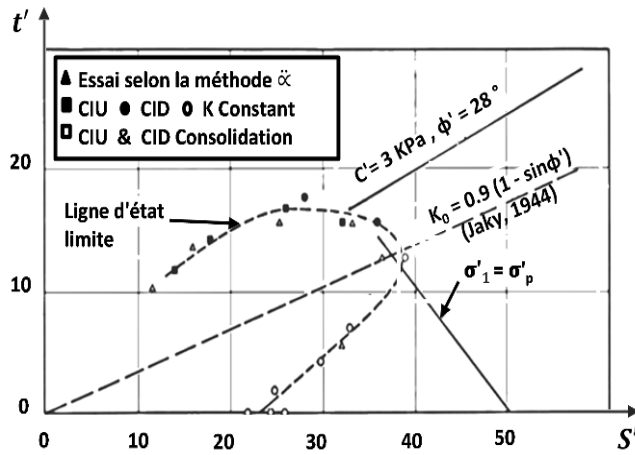


Figure 2.8 Surfaces de charge de l'argile de St-Alban Leroueil and Tavenas (1977).

3.3 Modèle de Larsson

Ce modèle proposé par Larsson (1977), est régi par les contraintes de préconsolidation verticale et horizontale $\sigma'_{v,p}$ et $\sigma'_{h,p}$. De plus, il se limite aux deux lignes d'état critiques de Mohr-Coulomb en compression et en traction. Ce modèle est présenté dans le plan de (σ', τ) . La surface de charge est déterminée par seulement quatre paramètres : les contraintes verticale et horizontale de préconsolidation $\sigma'_{v,p}$ et $\sigma'_{h,p}$, l'angle de frottement interne ϕ' et la cohésion c' .

$$\sigma'_1 = \sigma'_{v,p} \text{ et } \sigma'_3 = \sigma'_{h,p} \tag{2.11}$$

$$\tau = \sigma' \sin(\phi') + c' \cos(\phi') \tag{2.12}$$

$$\tau = \sigma' \sin(-\phi') + c' \cos(-\phi') \tag{2.13}$$

τ, σ' , déterminés comme suit :

$$\sigma' = \frac{(\sigma'_1 - \sigma'_3)}{2} \tag{2.14}$$

$$\tau = \frac{(\sigma'_1 + \sigma'_3)}{2} \tag{2.15}$$

Trois essais sont nécessaires pour déterminer les paramètres de ce modèle : un essai de cisaillement simple et deux essais œdométriques, un dans le plan vertical et l'autre dans le plan horizontal. La figure 2.9 ci-dessous représente la surface de charge du modèle de Larsson et son évolution sur les chemins de contraintes. La confrontation du modèle avec différentes études expérimentales sur argiles prouve le bon fonctionnement de ce modèle qui est relativement simple.




Figure 2.9 Modèle de Larsson appliqué sur l'argile de Drammen (Larsson, 1977).

3.4 Modèle Mélanie

3.4.1 Mélanie sans fluage

La mise au point du modèle s'est fondée sur les courbes d'état limite qui déterminent dans le plan « contraintes moyennes effectives - contraintes déviatoriques » (s' , t), un domaine de forme elliptique à l'intérieur duquel les déformations du sol sont supposées réversibles. Ces courbes d'état limite passent par l'origine des coordonnées et par le point de l'axe des abscisses $s'_p = 0.6 \times \sigma'_p$ (Tavenas et Leroueil, 1979). En plus, leur grand axe est confondu avec la droite représentant le coefficient K_0 (Figure 2.10).

L'ensemble des courbes d'état limite définies pour des valeurs de la pression de préconsolidation constituent dans l'espace (s' , t , e) une surface d'état limite qui sépare le domaine des états possibles du sol des états impossibles (Figure 2.11).

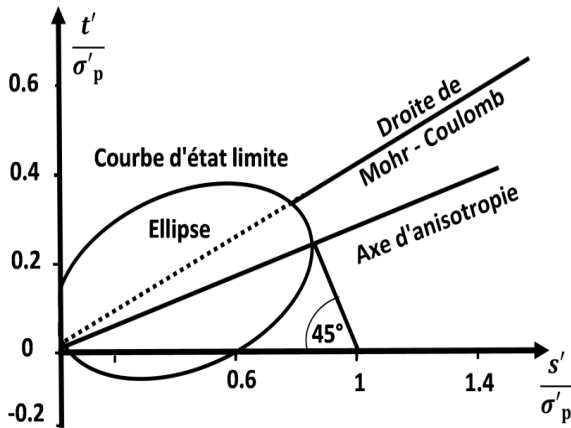


Figure 2.10 Courbe d'état limite des argiles molles naturelles.

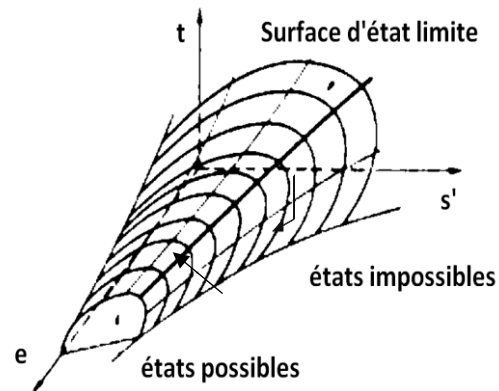


Figure 2.11 Surface d'état limite des argiles naturelles.

Dans le calcul numérique, ces courbes jouent le rôle de critère de plasticité, en séparant de façon formelle le comportement du sol supposé élastique linéaire à l'intérieur de la surface limite et le comportement plastique du sol avec écrouissage dès que l'on atteint la surface d'état limite. L'équation de la surface d'état limite est la suivante :

$$e = e_{\lambda 0} - \lambda \ln \left(\frac{s'}{s'_1} \right) \tag{2.16}$$

Dans laquelle e représente l'indice des vides, s' la contrainte moyenne, s'_1 la contrainte de référence ($s'_1=1$ kPa pour les applications), $e_{\lambda 0}$ et λ sont des constantes du sol. La courbe des déformations réversibles isotropes est une ellipse d'équation :

$$A^2 \left(s' \cos \theta + t \sin \theta - \frac{s'_p}{0.6A} \right)^2 + B^2 (t \cos \theta + s' \sin \theta) - \frac{s'_p}{0.6^2} = 0 \tag{2.17}$$

Avec s'_p la pression de préconsolidation. s' et t respectivement la contrainte moyenne et la contrainte déviatorique. Les paramètres A , B et θ sont donnés par :

$$A = 2(\sin \theta + \cos \theta) \tag{2.18}$$

$$B^2 = \frac{A^2 \cos \theta}{C \cos \theta^2} \left[\frac{2}{A} - \cos \theta \right] \tag{2.19}$$

$$\theta = \arctan \left[\frac{1 - K_0}{1 + K_0} \right] \tag{2.20}$$

3.4.2 Mélanie avec fluage

Pour modéliser le fluage, les auteurs se sont fondés sur le modèle unidimensionnel de Bjerrum (1967) et l'ont généralisé au cas des déformations planes en s'appuyant sur les résultats des études expérimentales de Leroueil et Tavenas (1977). Les travaux de ces auteurs, réalisés à l'université Laval du Québec, ont montré que le vieillissement des argiles molles produit une augmentation de la contrainte de préconsolidation et une augmentation homothétique de la surface d'état limite, semblable à ce qui se passe en cas d'érouissage plastique. Ils ont ensuite défini l'équation du réseau des courbes de la figure 2.12 en choisissant l'équation d'une de ces courbes et en définissant la loi de translation verticale de cette courbe en fonction du temps, avec l'hypothèse que la courbe de référence est la courbe vierge isotrope du modèle MELANIE, dont l'équation est :

$$e = e_{\lambda 0} - \lambda \ln \left(\frac{S'}{S'_1} \right) \tag{2.21}$$

Les courbes correspondant à d'autres valeurs du temps t peuvent être déduites de la courbe de référence par une translation verticale suivant une loi de fluage semi-logarithmique d'expression :

$$\Delta e^f = C_{\alpha e} \log \left(\frac{t}{t_i} \right) \tag{2.22}$$

Avec :

$C_{\alpha e}$: indice de fluage du sol, supposé indépendant de la contrainte effective.

t_i : temps de référence correspondant à la courbe vierge isotrope.

La variation de l'indice des vides due au fluage pendant le temps Δt est défini par la formule :

$$\Delta e^f = C_{\alpha e} \log \left(\frac{t^* + \Delta t}{t^*} \right) \tag{2.23}$$

Dans cette équation, t^* désigne la valeur du temps nécessaire pour que la courbe de compressibilité se décale jusqu'au point considéré par l'effet du fluage. Lépidas (1990) a admis que ce temps t^* pourrait être évalué comme suit :

- ❖ si l'état des contraintes du point se situe sur la courbe vierge isotrope ou sur la surface d'état limite, alors $t^*=t_i$ et $\Delta e^*=0$;
- ❖ si l'état de contraintes se trouve au-dessous de la courbe vierge isotrope, le temps t^* se calcule à partir de la contrainte moyenne correspondant à l'intersection d'une surface fictive homothétique à la surface d'état limite passant par le point considéré et l'axe Os' .




Figure 2.12 Les courbes isotropes de MELANIE (Lépidas 1990)

La prise en compte du fluage dans le modèle MELANIE a été réalisée avec l'hypothèse supplémentaire de Perzyna selon laquelle la direction du tenseur de déformation plastique dû au fluage est la même que celle de la déformation plastique, soit :

$$d\varepsilon_{ij}^f = d\lambda^f \frac{\partial g}{\partial \sigma_{ij}} = d\lambda^f \cdot G_{\sigma} \quad (2.24)$$

Avec $d\lambda^f$: multiplicateur de fluage.

3.5 Modèle Anpetal

Plusieurs modèles utilisés pour décrire le comportement d'une argile admettent que la surface de charge est axisymétrique sur l'axe de consolidation anisotrope (comme celui de Mélanie). Cependant, les études expérimentales sur l'argile d'Ottawa (Wong, 1975) et de l'argile de Winnipeg (Graham et al., 1988) indiquent la non symétrie de la surface de charge du sol naturel sur l'axe de consolidation anisotrope. La mise au point d'un autre type de modèle permettant d'exprimer la déformation de cette surface de charge a conduit à la naissance du modèle Anpetal. Il s'agit d'un modèle élastoplastique à élasticité non linéaire (Newson, 1997). Il permet de décrire le comportement d'une argile molle naturelle en tenant compte de la déformation de la surface de charge autour de l'axe de consolidation anisotrope en introduisant un angle, dit angle de Lode, dans l'équation de surface de charge (équation 2.25).

$$f(p', q) = (q - \eta_0 p')^2 + J(\theta) p'^2 \ln \left(\frac{p'}{p'_0} \right)^2 = 0 \quad (2.25)$$

$$J(\theta) = \frac{(a + b)}{2} + (b - a) \sin \theta \quad (2.26)$$

$$a = M_c (M_c - \eta_0) \quad (2.27)$$

$$b = M_e (M_e - \eta_0) \quad (2.28)$$

$$M_c = \frac{6 \sin \varphi'}{3 - \sin \varphi'} \quad (2.29)$$

$$M_e = \frac{3M_c}{3} + M_c \quad (2.30)$$

Dans ces équations, M_e et M_c représentent les pentes des droites $(q-p')$ à l'état critique respectivement d'un essai en extension et d'un essai en compression. φ' est l'angle de frottement interne et θ l'angle de Lode qui a pour valeurs dans les conditions triaxiales - 30° en compression et 30° extension.

La figure 2.13 montre la comparaison des résultats expérimentaux avec le modèle d'Anpetal sur différentes argiles naturelles (Argile de Mexico (a); argile de Bothkennar (b); argile d'Ottawa (c), (Newson, 1997)).




Figure 2.13 Validation du modèle Anpétal sur différentes argiles (Newson (1997)).

Les lois de comportement élastoplastique adaptées aux sols naturels décrites ci-dessus permettent une description satisfaisante du comportement des massifs de sols. Ces lois présentent aussi l'avantage d'une relative simplicité dans leur conception, dans leur traduction mathématique et d'un faible nombre de paramètres à identifier.

3.6 Modèle S-CLAY1S

Les argiles naturelles présentent une anisotropie et un effet de contact entre les particules. La déformation plastique implique un réarrangement et réalignement des particules. Par conséquent, la déformation plastique peut produire une déstructuration (la dégradation progressive des liaisons) et un changement d'anisotropie. Pour prendre ces effets en compte, Wheeler et al. (2003) ont développé un modèle élastoplastique anisotrope pour les argiles molles, normalement ou légèrement surconsolidées. Dans ce modèle, connu sous le nom de S-CLAY1, l'anisotropie du comportement plastique est représentée par une surface de charge inclinée, alors que le changement de l'anisotropie durant la déformation plastique est modélisé par une composante rotationnelle de la rigidité. Des simulations d'essais triaxiaux suivant plusieurs chemins de sollicitation sur des argiles de POKO reconstituées et anisotropiquement consolidées ont démontré que S-CLAY1 donne de bons résultats pour des argiles molles reconstituées mais l'évolution des liaisons entre particules et la dégradation de ces dernières ne sont pas prises en compte (Koskinen, et al., 2002a). Pour cela, Koskinen et al. (2002a) proposent un autre modèle, nommé S-CLAY1S. Pour ce modèle, la surface de charge est identique à celle du modèle S-CLAY1 qui est :

$$f = (q - \alpha p')^2 - (M^2 - \alpha^2)(p'_m - p')p' = 0 \quad (2.31)$$

M est le rapport ($\eta=q/p'$) pour un état critique, p'_m définie la taille de la surface de charge (Figure 2.14a) et α représente l'orientation de la surface de charge (une mesure d'anisotropie). Ce modèle tient compte de l'évolution des liaisons entre les particules du sol par le paramètre x qui définit le degré courant de liaison. Des simulations d'essais triaxiaux sur l'argile naturelle de POKO (Koskinen, et al., 2002b) et des prévisions du comportement de l'argile de Bothkennar sous cisaillement non drainé (Koskinen, et al., 2002b) ont démontré les capacités du modèle à reproduire l'effet de l'anisotropie et de la déstructuration de ces argiles (Figure 2.14b).

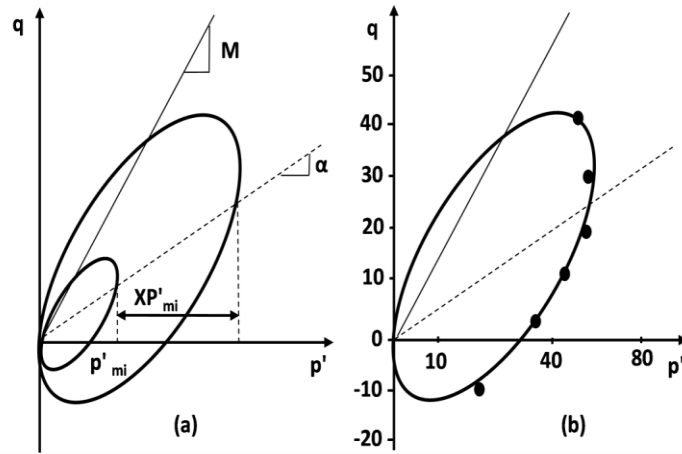


Figure 2.14 Surface de charge du modèle S-CLAY1S et l'argile de POKO (Koskinen, et al., 2002b).

3.7 Modèle de Sekiguchi-Ohta

Sekiguchi et Ohta (1977) ont proposé un modèle élastoplastique anisotrope avec écrouissage, qui est une extension du modèle de Cam-Clay pour les argiles normalement consolidées. Ce modèle a été largement appliqué au Japon dans les calculs par éléments finis pour prévoir les contraintes et les déformations des ouvrages géotechniques. La différence entre le modèle de Sekiguchi-Ohta et celui de Cam-Clay réside seulement dans le rapport η (q/p). Le rapport relatif η^* est utilisé dans le modèle de Sekiguchi-Ohta, qui prend en compte l'état de contrainte anisotrope initial. La surface de charge f et le potentiel de plasticité g sont donnés par les expressions suivantes :

$$f = g = \frac{\lambda - \kappa}{1 + e_0} \left(\ln \frac{p}{p_0} + \frac{\eta^*}{M} \right) - \varepsilon_v^p \quad (2.32)$$

λ et κ représentent respectivement les pentes de consolidation et de gonflement d'un essai œdométrique. M est la pente à l'état critique, e_0 représente l'indice des vides initial pour $p = p_0$, ε_v^p est la déformation volumique plastique utilisée comme paramètre d'écrouissage. Le paramètre η^* est défini par :

$$\eta^* = \sqrt{\frac{3}{2} (\eta_{ij} - \eta_{ij0})(\eta_{ij} - \eta_{ij0})} \quad (2.33)$$

Avec :

$$\eta_{ij} = \frac{\sigma_{ij} - p\delta_{ij}}{p} \quad (2.34)$$

$$\eta_{ij0} = \frac{\sigma_{ij0} - p_0\delta_{ij}}{p_0} \quad (2.35)$$

σ_{ij0} est la valeur de σ_{ij} à la fin de la consolidation anisotrope et δ_{ij} est le symbole de Kronecker. Il faut noter que les paramètres (λ , κ , M et v) du modèle de Sakiguchi-Ohta sont identiques à ceux du modèle de Cam Clay.

4 Modèles numériques

Dans les modèles élastoplastiques, le temps n'intervient que facteur de chargement, il n'a pas d'influence sur le comportement intrinsèque des matériaux. L'introduction d'un terme relatif aux propriétés visqueuses s'est avérée nécessaire. La majorité des modèles proposés se sont basés sur le

concept de l'élasto-visco-plasticité (EVP) de Perzyna (Perzyna, 1966). Dans ce cas, certains auteurs ont divisé la déformation totale en une composante élastique et une composante viscoplastique (Adachi et Oka 1982; Desai et Zhang 1987; Yin et Graham, 1989). D'autres chercheurs comme Borja et Kavazanjian (1985) ont divisé la déformation totale en trois parties : élastique, plastique et viscoplastique. La formulation de la déformation viscoplastique reste la même proposée par Perzyna (1963, 1966). Ces modèles ainsi que ceux décrits dans les paragraphes précédents ont fait l'objet d'application sur des sites argileux compressibles pour juger de leurs pertinences. Le tableau 2.1 ci-dessous résume les travaux recensés dans la littérature disponible.

Trois types d'analyse ont été menés par les chercheurs : en conditions non drainées, en conditions drainées et avec prise en compte de la consolidation. Historiquement, les calculs en consolidation n'étaient possibles qu'avec qu'avec l'apparition d'ordinateurs performants dans les années 1980. Le modèle le plus employé est le modèle de Mohr-Coulomb avec une élasticité linéaire isotrope. Parmi les lois élastoplastiques avec écrouissage, le modèle Cam-Clay demeure le plus utilisé. Le tableau 2.1 montre la décroissance de l'utilisation de l'élasticité linéaire ou non linéaire en faveur de l'élasto-plasticité et de l'élasto-visco-plasticité.

Tableau 2.1 Modèles de comportement et leurs applications pratiques.

Référence	Site	Terrain	Tc (j)	H (m)	S _{max Ex} (cm)	S _{max EF} (cm)	Analyse	Modèle
Wroth et Simpson (1972)	King's Lynn (UK)	Argiles molles, tourbes	700	4,5	80	73,5	EP-D	Cam-Clay modifié
J. Magnan et al. (1982)	Cubzac B (France)	Argiles molles	1040	2,3	65,8	52,3	CEP	Mélanie
			1040	2,3	65,8	59	CEP	Cam-Clay modifié
			2000	2,3	79	66	CEP	Mélanie
Redman et Poulos (1984)	Atchafalaya (Loisiane, EU)	Argiles molles, tourbes	540		82,6	70,7	VP-U	Mohr-Coulomb + fluage
Redman et Poulos (1984)	Boston (EU)	Argiles	2000	12	115,3	96,1	VP-U	Mohr-Coulomb + fluage
Kavazanjian et al. (1985)	Boston (EU)	Argiles	2200		112,5	80	CEVP	Extension Cam-Clay
Matsuoka et Sakakibara (1987)	Kanda (Japon)	Argiles molles, sables	200	10	117,4	107,6	CEP	Ecrouisseage
Ohta et Iizuka (1988)	Kanda (Japon)	Argiles molles, sables	300	10	114,3	116,7	CEVP	Extension Cam-Clay
Ali et Mohamadi (1989)	Muar Flats (Malaisie)	Argiles molles	520	5,4	97,1	114	CEP	Cam-Clay modifié
Borja et al. (1990)	Boston (EU)	Argiles, sols mous	2120	8,84	106,5	96,8	CEP	Cam-Clay modifié
Ali et Hashim (1991)	Ouest de la Malaisie	Argiles molles	250	3	76,5	81,6	CEP	Cam-Clay modifié
Ohta et al. (1991)	Kitakata (Japon)	Argiles, limons, graves	370	8,5	209,8	227,7	CEVP	Sekiguchi et Ohta
Ohta et al. (1991)	Kitakata (Japon)	Argiles, limons, graves	380	8,5	264,7	269,1	CEVP	Sekiguchi et Ohta
Ohta et al. (1991)	Kitakata (Japon)	Argiles, limons, graves	450	8,5	234,4	223,2	CEVP	Sekiguchi et Ohta
Ohta et al. (1991)	Kitakata (Japon)	Argiles, limons, graves	330	7	151,1	177,8	CEVP	Sekiguchi et Ohta
Ohta et al. (1991)	Kitakata (Japon)	Argiles, limons, graves	410	7,7	133,3	130	CEVP	Sekiguchi et Ohta
Vepsäläinen et al. (1991)	Vaasa (Finlande)	Argiles molles	500	2	39	27,3	CEP	Cam-Clay modifié
Vepsäläinen et al. (1991)	Paimio (Finlande)	Argiles molles	300	1,85	5,67	5,2	CEP	Cam-Clay modifié
Koehorst et al. (1992)	Vaasa (Finlande)	Argiles molles	500	2	41,9	43,8	CVP	Cam-Clay modifié
Colleselli et Cortellazzo (1992)	Sermide (Italie)	Sols mous	300	8,6	47,7	44,4	CEP	Cam-Clay modifié
Colleselli et Cortellazzo (1992)	Volta Vaccari (Italie)	Argiles, sables, limons	1550	6	104,4	112,2	CEP	Cam-Clay modifié
Ladd et al. (1994)	Boston (EU)	Argiles	2160	12,2	71,4	54,3	CEP	Cam-Clay modifié
Mimura et Teunissen (1995)	Rotterdam (Pays-Bas)	Argiles molles, tourbes	1000	7,15	227,8	236,1	CEVP	Sekiguchi
Kamei et Sakajo (1995)	Kanda (Japon)	Argiles molles, sables	350	10	116,3	110,2	CEP	Sekiguchi et Ohta
Brugger et al. (1998)	Sergipe (Brésil)	Argiles	1350	15,3	104,1	102,5	CEP	Cam-Clay modifié
Hinchberg er et Rowe (1998)	Gloucester (Canada)	Sols mous	1500	5,70	36,2	35,5	CEVP	Cap model + fluage
Aalto et al. (1998)	Haarajoki (Finlande)	Argiles, limons	300	2,9	22,7	22,3	CEP	Cam-Clay modifié
Naatanen et al. (1998)	Haarajoki (Finlande)	Argiles, limons	270	2,9	22		CEP	Cam-Clay modifié
The et al. (1998)	Vaasa (Finlande)	Argiles molles	500	2	41,2	46,3	CEVP	Extension Cam-Clay
Mitachi et Fukuda (1998)	Sapporo (Japon)	Argiles, limons, tourbes	175	2	98,3	91,7	CEP	Cam-Clay modifié
Hayashi et al. (1998)	Hokkaido (Japon)	Argiles molles, tourbes	280	4,7	155	150	CEP	Cam-Clay modifié
Sun et al. (2001)	Kanda (Japon)	Argiles, sables	300	10	114,5	120	CEP	Sekiguchi et Ohta Anisotropie
Neher et al. (2001)	Boston (EU)	Argiles	2000	11	75	69	CEVP	Soft Soil Creep model

CHAPITRE II

ANALYSE DIRECTE ET INVERSE DANS LE CALCUL GEOTECHNIQUE

Neher et al. (2001)	Boston (EU)	Argiles	2000	11	75	48	CEP	Soft Soil model
Neher et al. (2001)	Ska Edeby (Suède)	Argiles molles	20 ans	1,5	90	84,4	CEVP	Soft Soil Creep model
Neher et al. (2001)	Ska Edeby (Suède)	Argiles molles	20 ans	1,5	90	19,7	CEP	Soft Soil model
Samieh (2002)	Egypte	Argiles molles et colonnes ballastées	200	16,5	31	34	CEP	Mohr-Coulomb + HSM
Tennekoon et al. (2002)	Ham (Belgique)	Résidus boueux	1300	4,16	140	110	CEP	Mohr-Coulmb + HSM
Koskinen et al. (2002)	Murro (Finlande)	Argiles	8 ans	2	800	790	CEP	Soft Soil model
Sun et al. (2004)		Argiles, tourbes, sables	300	10	790	900	CEP	Sekiguchi et Ohta
Hirochika et al. (2012)	Hokkaido (Japon)	Argiles, tourbes, sables	300	5	300	320	CEP	Cam-Clay modifié
Mohammad Ali (2014)	Boston (USA)	Argiles, tourbes	2000	12	31	29	CEP	SSCM
Ozutsumi et al.(2015)	Hitachi (Japon)	Argiles	430	9.5	125	170	CEP	Sekiguchi et Ohta
Gustav et al.(2015)	Boston (USA)	Argiles	2160	12,2	81	80	CEP	SSCM
Ozutsumi et al.(2015)	Hitachi (Japon)	Argiles	430	9.5	125	140	CEP	Cookie model
Sivasithamparam et Rezania (2017)	Seinäjoki (Finland)	Argiles	4000	23	80	112	CEP	Sekiguchi et Ohta

T_c: durée de la comparaison calculs- mesures, D: calcul drainé, U: calcul non drainé. SSCM : Soft Soil Creep model
 EP: élastoplasticité, VP: viscoplasticité, CEP: consolidation élastoplastique. CEVP: consolidation élasto-viscoplasticité.

5 Programmes de calculs

La prolifération des modèles de comportement a conduit les chercheurs et les laboratoires de recherche en géotechnique à développer des logiciels ou des codes de calcul dans lesquels sont incorporés ces modèles. Ces codes de calculs mis sur le marché utilisent en majorité la méthode des éléments pour leurs mises en œuvre. Le but de ces codes est surtout de faciliter l'utilisation des divers modèles de comportement proposés, de diversifier les sites d'application et de juger de leurs fiabilités, l'objectif final étant la mise entre des ingénieurs des outils de calcul permettant de justifier des ouvrages complexes sur des sites difficiles.

Dans ce qui suit, un inventaire sommaire est donné concernant ces codes de calcul et particulièrement ceux qui font intervenir une loi de comportement de fluage.

5.1 CONDES

Le code de calcul par différences finis CONDES a été développé à l'université du Colorado à Boulder (Yao et Znidarcic, 1997). Le code est utilisé pour la résolution de nombreux problèmes pratiques tels que les fondations, tunnels et ouvrages de soutènement. Le code fournit une solution numérique au problème de la consolidation unidimensionnelle et fluage en résolvant l'équation de Gibson et al. (1967). Le modèle constitutif utilisé dans CONDES définit la relation entre l'indice des vides et la contrainte effective d'une part, et d'autre part, la relation entre la conductivité hydraulique et l'indice des vides. Ces relations sont données par les équations 2.36 et 2.37 ci-dessous :

$$e = A \times (\sigma' + Z)^B \quad (2.36)$$

$$k = C \times e^D \quad (2.37)$$

$$A = \frac{e_0}{Z^B} \quad (2.38)$$

$$B = \frac{\ln \frac{e_1}{e_0}}{\ln \frac{\sigma'_1 + Z}{Z}} \quad (2.39)$$

$$C = \frac{k_1}{e_1^D} \quad (2.40)$$

$$D = \frac{\ln \frac{k_1}{C}}{\ln e_1} \quad (2.41)$$

$$Z = \frac{\sigma'_1}{\left(\frac{e_1}{e_0}\right)^{\frac{1}{B}} - 1} \quad (2.42)$$

Dans ces relations, e_0 et e_1 représentent respectivement l'indice de vide initiale et l'indice de vide à la fin de consolidation, k_1 est la conductivité hydraulique à la fin de la consolidation. Les paramètres A, B, Z, C et D pourrait être obtenu en ajustant indépendamment les modèles explicites existant aux données expérimentales disponibles. Les paramètres A, B et Z définissent la courbe de compressibilité (e- σ'). Les paramètres C et D définissent la courbe de perméabilité (e-k). Les modèles de calcul implémentés dans le code CONDES couvrent pratiquement l'ensemble des aspects théoriques et expérimentaux du comportement des sols courants.

5.2 Mathematica (Wolfram, 1999)

Mathematica est un logiciel général pour le calcul scientifique et technique. Ses applications recouvrent tous les domaines de la science et de la technologie comme la physique, les mathématiques, la biologie, l'informatique, la finance, l'économie, etc. Un programme simplifié de différences finies pour la consolidation non-linéaire et la compression secondaire a été implantée sur Mathematica. Les équations de base utilisées sont présentées par les équations 2.43 et 2.44 ci-dessous :

$$\frac{1}{\gamma_w} \left(k \frac{\partial^2 u}{\partial z^2} + \frac{\partial u}{\partial z} \frac{\partial k}{\partial z} \right) - \frac{a_v}{1 + e_0} \frac{\partial u}{\partial t} = 0 \quad (t < t_{ref}) \quad (2.43)$$

$$\frac{1}{\gamma_w} \left(k \frac{\partial^2 u}{\partial z^2} + \frac{\partial u}{\partial z} \frac{\partial k}{\partial z} \right) - \frac{a_v}{1 + e_0} \frac{\partial u}{\partial t} + \frac{\alpha}{t(1 + e_0)} = 0 \quad (t \geq t_{ref}) \quad (2.44)$$

L'équation 2.43 tient compte de la consolidation non-linéaire sans fluage, c'est-à-dire que l'équation 2.43 est utilisée pour évaluer le comportement des sols pendant la période de consolidation primaire ($t < t_{ref}$).

L'équation 2.44 explique la compression secondaire du sol, c'est-à-dire qu'elle est utilisée pour des temps supérieurs à t_{ref} . Alternativement, le facteur $1/t$ peut être éliminé de l'équation 2.44 en utilisant l'équation 2.45 proposée par Brandenburg (2016).

$$\frac{1}{t} = \frac{1}{t_{ref}} \exp \left(\frac{e - e_{ca,ref}}{\alpha} + \frac{C_c}{\alpha} \log_{10} \left[\frac{\sigma'_v}{\sigma'_{vca,ref}} \right] \right) \quad (2.45)$$

$$\alpha = \frac{C_\alpha}{\ln 10} \quad (2.46)$$

Les paramètres d'entrée requis pour le modèle Mathematica sont la hauteur initiale de la couche du sol (h_0), l'indice de vide initial (e_0), la contrainte verticale appliquée (σ_v), l'indice de compression (C_c) et l'indice des vides de référence (e_{ref}), le poids volumique des grains solide (γ_s), le coefficient de perméabilité C_k , l'indice de compression secondaire C_α et le temps qui définit le début de compression secondaire (t_{ref}).

5.3 iConsol.js

Le programme iConsol.js est un code implicite pour résoudre des problèmes unidimensionnels de consolidation non-linéaire et de compression secondaire, développé par Brandenburg (2016) en tant que JavaScript et déployé via une interface HTML. Le taux de déformation volumétrique dû à la compression secondaire peut être défini en utilisant les constantes du matériau (t_{ref}), ($e_{ca, ref}$), (σ'_{vca}) et C_α (Equation 2.47), qui peuvent toutes être mesurées à l'aide d'un essai œdométrique traditionnel pour lequel le comportement de compression secondaire est linéaire dans l'espace $e - \log_{10}(t)$.

$$\varepsilon_{v,sc} = \frac{\alpha}{t_{ref}(1 + e_0)} \exp \left[\frac{e - e_{ca,ref}}{\alpha} + \frac{C_c}{\alpha} \log \left(\frac{\sigma'_v}{\sigma'_{vca,ref}} \right) \right] \quad (2.47)$$

Le taux de déformation volumétrique dû à la consolidation primaire peut être exprimé en termes de coefficient de compressibilité, comme le montre l'équation 2.48 ci-dessous :

$$\varepsilon_{v,pc} = - \frac{\alpha_v}{(1 + e)} \frac{du}{dt} \quad (2.48)$$

Avec

$$\alpha_v = \frac{de}{d\sigma'_v} \quad (2.49)$$

Les entrées du modèle de Brandenberg (2016) sont similaires aux entrées du modèle développé dans Mathematica. Cependant, le modèle de Brandenberg (2016) tient compte de la recompression et du gonflement et nécessite donc des entrées supplémentaires, l'indice de recompression C_s et le rapport de surconsolidation OCR. Le modèle de Brandenberg (2016) tient compte de la compression secondaire. Cependant, il suppose que le coefficient C_α définissant les déformations de fluage est constant.

5.4 CONMULT

Le programme CONMULT a été initialement développé pour la résolution de l'équation classique de la consolidation unidimensionnelle dans le cas d'un massif multicouches. Il résout numériquement les équations différentielles à paramètres constants à l'intérieur de chacune des couches du massif, avec des équations de continuité quand on passe d'une couche à une autre. Compte tenu de la loi de comportement adoptée pour le squelette, le code résout en pratique l'équation approchée suivante (Magnan, 1984):

$$\frac{\partial u}{\partial t} - \frac{C_{\alpha e}}{0.434} \frac{\sigma'_v}{C_x} \frac{1}{t^*} = C_v \frac{\partial^2 u}{\partial z^2} \quad (2.50)$$

Dans cette équation, z représente la coordonnée verticale dans la couche compressible, t le temps depuis le début du calcul, σ'_v la contrainte effective verticale au temps t , ; $C_{\alpha e}$ l'indice de fluage (coefficient de la relation semi-logarithmique entre les variations de l'indice des vides et du logarithme du temps), t^* est le temps fictif permettant de calculer la vitesse de fluage du sol en fonction de l'indice des vides et de la contrainte effective verticale à l'instant considéré et C_x est le paramètre de compressibilité, égal à C_s si $\sigma'_v < \sigma'_p$ ou à C_c dans le cas contraire.

Le coefficient de consolidation C_v est donné par la formule suivante :

$$C_v = \frac{k_v(t)[1 + e(t)] \sigma'_v(t)}{0.434 \gamma_w C_x} \quad (2.51)$$

Avec k_v le coefficient de perméabilité, calculé en fonction de l'indice des vides initial e_0 et de l'indice des vides au temps t . C_k est le taux de variation de la perméabilité en fonction de l'indice des vides e . γ_w est le poids volumique de l'eau interstitielle (10 kN/m^3).

La résolution numérique des équations précédentes est réalisée par la méthode des différences finies avec discrétisation automatique de l'espace et du temps, de façon à maximiser la vitesse du calcul numérique, tout en assurant la convergence de la solution. Le détail des équations discrétisées a été présenté par Magnan (1984). Les paramètres nécessaires au calcul sont des paramètres classiques de la mécanique des sols, que l'on déduit simplement d'essais œdométriques à chargement par paliers de 24 heures (e_0 , C_c , C_s), d'essais de fluage à l'œdomètre et d'essais classiques de caractérisation de l'état du sol. Le coefficient de compressibilité de l'eau interstitielle a_w dépend du degré de saturation S_r et de la pression interstitielle u . Le coefficient de perméabilité verticale k_v et sa loi de variation avec l'indice des vides C_k peuvent être déduits d'essais œdométriques ou d'essais de perméabilité à l'œdomètre.

5.5 CESAR-LCPC

Le module de résolution CSNL (Consolidation des Sols à comportement Non Linéaire) permet de résoudre des problèmes hydromécaniques statiques dans lesquels peuvent intervenir divers types de matériaux (sols quasi-saturés, bétons, roches et métaux). Plusieurs lois de comportement élastoplastiques adaptées à ces matériaux ont été introduites. La programmation en comportement mécanique non-linéaire suit l'algorithme classique des méthodes de Newton-Raphson et de Galerkin. A chaque étape de la résolution correspond l'appel d'un sous-programme du niveau global. Pour faciliter la compréhension de l'algorithme, il convient de rappeler le système algébrique à résoudre obtenu après discrétisations en temps et en espace :

$$\begin{bmatrix} \mathbf{R} & -\alpha \mathbf{C}^T \\ -\alpha \mathbf{C}^T & -\alpha^2 \left(\mathbf{E}_c + \frac{2\Delta t}{3} \mathbf{K} \right) \end{bmatrix} \begin{bmatrix} \Delta \mathbf{U}(\Delta t) \\ \frac{\Delta H(\Delta t)}{\alpha} \end{bmatrix} = \begin{bmatrix} \mathbf{0} & \frac{3}{2} \alpha \mathbf{C} \\ \mathbf{0} & \alpha^2 \Delta t \mathbf{K} \end{bmatrix} \begin{bmatrix} \mathbf{U}^t \\ \mathbf{H}^t \end{bmatrix} + \begin{bmatrix} \frac{1}{2} \mathbf{F}(t) + \mathbf{F}(t + \Delta t) + \mathbf{F}_{\Delta \sigma^p}(t + \Delta t) - \frac{3}{2} \mathbf{F}_\sigma(t) \\ -\alpha \frac{\Delta t}{3} [\mathbf{Q}(t) + 2\mathbf{Q}(t + \Delta t)] \end{bmatrix} \quad (2.52)$$

Les différentes variables de cette équation sont : U le champ de déplacement, H le champ de charge hydraulique, R la matrice de rigidité du squelette du sol, C la matrice de couplage, CT la matrice transposée, K la matrice des perméabilités, F le vecteur représentant le chargement dû aux conditions aux limites mécaniques (contraintes ou déplacement imposés), à la présence de forces volumiques et à la prise en compte d'un état de contraintes initial éventuel, Q le vecteur représentant le chargement dû aux conditions aux limites hydrauliques (flux ou charges imposés), $\mathbf{F}_{\Delta \sigma^p}(t + \Delta t)$ le vecteur des efforts internes dû au champ de déformations plastiques et $\mathbf{F}_\sigma(t)$ le vecteur des efforts internes correspondant au champ de contraintes effectives à l'instant t.

5.6 PLAXIS

Le code de calcul par éléments finis PLAXIS a été développé en premier lieu à l'université technologique de Delft (TUD) en 1987. Dans les années suivantes, ce code, initialement réalisé pour analyser les digues en sols mous (argileux), a vu son champ d'application se développer afin de pouvoir traiter différents types de problèmes géotechniques. Dans le modèle de fluage, la déformation de fin de consolidation est définie par l'équation suivante :

$$\varepsilon_c = \varepsilon_c^e + \varepsilon_c^c = -a \ln \left(\frac{\sigma'}{\sigma'_0} \right) - (a - b) \ln \left(\frac{\sigma_{pc}}{\sigma_{p0}} \right) \quad (2.53)$$

où ε_c est la déformation logarithmique globale due à l'augmentation de la contrainte effective de σ à σ' et au développement de la consolidation secondaire. Les paramètres a et b sont définis par l'équation 2.54 et 2.55. C_s est l'indice de gonflement et C_c est l'indice de compression.

$$a = \frac{C_s}{(1 + e_0) \times \ln 10} \quad (2.54)$$

$$b = \frac{C_c}{(1 + e_0) \times \ln 10} \quad (2.55)$$

Sur la base de l'équation 2.53, il est possible de formuler l'équation du fluage différentiel, qui est exprimée sous la forme de l'équation 2.56. Le paramètre c est défini par l'équation 2.57, où C_a est l'indice de fluage, σ_p est la contrainte de préconsolidation et τ représente la durée du chargement (généralement un jour).

$$\dot{\varepsilon} = \dot{\varepsilon}^e + \dot{\varepsilon}^c = -a \times \left(\frac{\dot{\sigma}'}{\sigma'} \right) - \frac{c}{\tau} \times \left(\frac{\sigma}{\sigma_p} \right)^{\frac{b-a}{c}} \quad (2.56)$$

$$c = \frac{c_\alpha}{(1 + e_0) \times \ln 10} \quad (2.57)$$

Les paramètres d'entrée du modèle Soft-Soil (Sols mous) incluent la cohésion effective, l'angle de frottement, l'angle de dilatance, le coefficient de Poisson en charge-décharge, l'indice du gonflement modifié, l'indice de compression modifié, l'indice du fluage modifié, l'indice de vide initial, le poids volumique, le degré de surconsolidation (OCR) et le poids des terres de préconsolidation (POP). PLAXIS peut produire des résultats erronés pour les valeurs d'indice de compression secondaire approchant le seuil de $C_\alpha = 0,0001$, c'est-à-dire la valeur minimale autorisée en tant qu'entrée dans le modèle de fluage des sols mous (Alhusein, 2001).

6 Analyse inverse

Dans le domaine de la géotechnique, le rôle des modèles constitutifs de sols est de décrire au mieux la réalité observée (Nova, 2005). Ces modèles doivent être appliqués avec précaution lors des calculs car ces derniers sont formulés en utilisant de nombreux paramètres sensés caractériser les sols. Or, il faut que ces paramètres soient bien déterminés. En pratique, les ingénieurs cherchent les valeurs de ces paramètres en se basant sur les résultats de tests disponibles. Ces valeurs sont ensuite utilisées pour simuler le comportement des sols. La procédure consiste donc à déterminer les paramètres qui caractérisent le sol, les injecter dans le programme et simuler le comportement du sol sous divers chemins de sollicitations. La réponse ou la solution obtenue constitue ce qu'on appelle « analyse directe » schématisée par la figure 2.15 ci-dessous.




Figure 2.15 Schéma de principe d'une analyse directe.

Quel que soit le modèle ou la méthode numérique utilisés, les résultats des calculs sont limités par les incertitudes liées à la détermination des paramètres introduits en entrée. C'est ce contexte qui a donné naissance à la problématique de l'analyse inverse en géotechnique. Celle-ci peut être formulée comme suit : Quelles informations concernant les paramètres constitutifs du sol est-il possible d'obtenir à partir de mesures géotechniques in situ ? En d'autres termes, si des informations sont disponibles sur des comportements passés, comment peut-on les utiliser pour améliorer les réponses des modèles par un « retour d'expérience ». En général, pour un chemin de sollicitation correspondant aux observations disponibles, les valeurs d'entrée à donner au modèle sont ajustées pour reproduire le comportement observé. L'analyse liée à ce retour d'expérience constitue ce que nous appelons l'analyse inverse.

6.1 Analyse inverse en géotechnique

Afin de limiter les choix subjectifs, effectués par l'ingénieur géotechnicien dans l'estimation des paramètres des modèles constitutifs, suite au manque d'essais de laboratoire, Gioda (1985) était le premier à proposer de caler les modèles des sols par analyse inverse. Ses travaux ont largement participé à la diffusion de la notion d'analyse inverse en géotechnique. Selon Gioda et Sakurai (1987), le retour d'expérience ainsi que le jugement de l'ingénieur restent des ingrédients fondamentaux de toute analyse inverse. Cela se manifeste lors du choix d'une loi de comportement raisonnable et un modèle géométrique simple représentant un problème complexe. Anandarajah et Agarwal (1991) ont montré que les données obtenues in situ sont préférables aux données de

laboratoire car les essais in situ sont plus représentatifs du milieu. Honjo et Kashiwagi (1999) proposent l'utilisation de l'analyse statistique et la théorie des probabilités dans les méthodes d'analyse inverse pour résoudre des problèmes hydrologiques. Ils affirment que la disponibilité a priori des données statistiques minimisent les erreurs sur l'estimation des paramètres. Lee et Kim (1999) ont repris la même idée pour minimiser les incertitudes des modèles géotechniques dans la détermination des paramètres de sols. Cependant, la formulation implicite impose une connaissance préalable des caractéristiques statistiques de l'erreur comme l'erreur de représentativité. Or, la rare possibilité de quantifier l'information a priori statistique, limite beaucoup l'application de cette approche. Ces difficultés d'application vont donner naissance à différentes méthodes d'optimisation comme le recuit simulé et les algorithmes génétiques. L'optimisation par les algorithmes génétiques reste un outil de qualité pour optimiser des problèmes variés en géotechnique. Cependant, comme le souligne Goh (1999), malgré la puissance des algorithmes génétiques, leur utilisation reste gourmande en terme de temps de calculs. McCombie et Wilkinson (2002) ont utilisé un algorithme génétique pour résoudre des problèmes de stabilité de pentes. A travers une étude comparative entre un algorithme génétique et une optimisation classique de Monte Carlo, ils trouvent que l'algorithme génétique est beaucoup plus efficace qu'un algorithme traditionnel. Par la suite, Samarajiva et al. (2005) ont appliqué les algorithmes génétiques dans le calage des paramètres d'un modèle sur des essais de laboratoire. Ils ont montré que contrairement à d'autres méthodes de calage, l'utilisation d'un algorithme génétique est très avantageuse pour tenir compte de plusieurs caractéristiques globales des résultats d'essais de laboratoire selon chaque chemin de contrainte. Levasseur et al. (2005) ont expliqué, à leurs tours, qu'un algorithme génétique permet d'identifier un plus grand nombre de paramètres, il détecte en plus s'il y'a corrélation. Contrairement aux méthodes de gradient, qui ne sont pas adaptées à ces cas, Pedro et al. (2017) ont étudié l'utilisation des algorithmes génétiques pour identifier des paramètres avancés de modèles constitutifs, qui sont utilisés pour simuler l'excavation. Ils concluent que les algorithmes génétiques permettent de résoudre des problèmes larges, discrets et non-linéaires malgré un manque d'information. Cet avantage revient du fait qu'ils fonctionnent d'une manière aveugle et ils convergent dans des cas complexes. Dans la même année, Ye et al. (2016) ont étudié, en utilisant l'analyse inverse, l'identification des paramètres d'un modèle constitutif de sol « elastic-viscoplastic » en se basant sur des résultats d'essais triaxiaux sur de l'argile marine de Wenzhou. A travers cette étude, ils ont prouvé l'efficacité et la robustesse de cette méthode. Yin et al. (2017) se sont intéresser à l'utilisation de l'analyse inverse pour caler les propriétés d'un sol sur des résultats d'excavations profondes. Leur étude met le point sur les difficultés actuelles d'améliorer l'estimation des constantes relatives à la modélisation des excavations profondes par la méthode classique des éléments finis. Le tableau suivant résume l'ensemble des travaux en relation avec ce sujet dans le domaine de la géotechnique.

Tableau 2.2 Méthodes développées pour résoudre des problèmes d'optimisation.

Référence	Modèle	Algorithme	Paramètres	Application
Kim et Finno (2019)	HSM HSSM	DG	$E_{50}^{ref}, E_{ur}^{ref}, E_{oed}^{ref}, G_0^{ref}, \gamma_{0.7}$	Excavation à Chicago
Wang et al. (2019)	HSM	EDF	$E_{50}^{ref}, E_{ur}^{ref}, E_{oed}^{ref}, G_0^{ref}$	Excavation à Singapour
Latorre et Moret-Fernández (2019)	VGF	DG- ASSRS	$K_s, \alpha, n, \theta(h)$	Problème d'infiltration
Jin et al. (2019)	MC	GA	ε_{70}, n, ν	Excavation à Taipei
Park et al. (2019)	HSM	GA-PSO	H, q, L, C	Excavation à Shenzhen Holiday Plaza
Kim et Finno (2020)	HCM	DG	v_{pp}, R_{max}	Excavation à Chicago
Zhang et al. (2020)	CVEM	PSO GP-PSO	μ, E, η	Centrale de pompage de Taian
Li et al. (2020)	HBFC	PSO GA	D, GSI, m_i	Mine Baskoyak en Turquie

H = Hauteur d'excavation, q = La charge, φ = Angle de frottement du sol, C = Cohésion du sol, L= Épaisseur de la paroi, E_{50}^{ref} = Le module sécant à 50% de déformation de référence, E_{oed}^{ref} = Le module œdométrique à la pression de référence, E_{ur}^{ref} = Le module de chargement – déchargement de référence, G_0^{ref} = Le module de cisaillement de référence, $\gamma_{0.7}$ = La déformation en cisaillement auquel le module de cisaillement sécant est réduit à 70% de sa valeur initiale, v_{pp} : Paramètre d'ajustement de la rigidité, R_{max} : la taille de la zone élastique, μ = coefficient de Poisson, E = module d'élasticité, η = coefficient de viscosité, D = le facteur de perturbation, GSI = indice de résistance géologique, m_i = constante de matériau pour une masse rocheuse intacte. HBFC : Critère de rupture Hoek Brown. CVEM : Modèle viscoélastique classique. HCM: Modèle d'argile hypoplastique. HSM: Modèle Hardening Soil. MC: Mohr-Coulomb. VGF: Fonction de Van Genuchten. HSM: Modèle Hardening Soil. HSSM: Modèle Hardening Soil Small. PSO: Optimisation par essais particuliers ; GA: algorithme génétique ; GP-PSO: Processus gaussien optimisé par les essais particuliers ; DG: descente gradient ; DG- ASSRS: descente gradient optimisé par une recherche aléatoire de pas adaptative ; EDF: Falsification du domaine d'erreur.

6.2 Résolution des problèmes inverses

Le principe de l'analyse inverse a été introduit par Parker et Santamarina dans le domaine de la géophysique et du génie civil (Parker, 1977; Santamarina et Fratta, 1998). Ils ont proposé deux types d'approches pour résoudre les problèmes inverses : la méthode analytique inverse et l'analyse inverse par méthode numérique directe.

6.2.1 Méthode analytique inverse

Dans le cas où les données du problème sont connues et bien maîtrisées, le problème peut être résolu analytiquement en appliquant les théories de mathématiques appliquées. Alors, inverser les équations du modèle constitutif permet de déterminer les paramètres de sols comme schématisée dans la figure 2.16. Cette analyse inverse est nommée méthode analytique inverse.

L'inversion analytique du problème est presque impossible à passer en géotechnique. Les systèmes géo-mécaniques et les modèles associés sont complexes et hautement non-linéaires. Les équations de comportement sont généralement irréversibles. Tout cela rend la solution du problème inverse non unique, voire inexistante (Lecampion et al. 2002). La résolution du problème inverse peut se faire alors par méthode numérique directe

6.2.2 Analyse inverse par méthode numérique directe

Lorsque les données du problème sont incomplètes ou incertaines, trouver une solution analytique devient difficile. La solution est sensible aux données et aux erreurs sur ces données.

Santamarina et Fratta (1998) recommande une résolution numérique basée sur des simulations successives par éléments finis. Ce processus schématisée sur la figure 2.17 est appelée l'analyse inverse par méthode numérique directe.




Figure 2.16 Schéma d'une méthode analytique inverse.




Figure 2.17 Schéma d'une analyse inverse par méthode numérique directe.

Cette procédure, qui est itérative, évalue successivement une fonction erreur caractérisant l'écart entre les observations expérimentales et les évaluations numériques obtenues suite à une analyse des contraintes du problème géotechnique. La résolution par minimisation directe de la distance entre les mesures in situ et les valeurs numériques correspondantes est préférable puisqu'elle évite l'inversion des équations d'analyse des contraintes.

6.3 Procédure de l'analyse inverse par méthode numérique directe

Cette méthode consiste à résoudre numériquement un problème géotechnique par des simulations éléments finis successives à partir de paramètres mécaniques. Le modèle numérique du sol est calé sur les données expérimentales par modifications itératives des valeurs des paramètres d'entrée du modèle jusqu'à ce que les valeurs en sortie reproduisent au mieux les données observées. La première étape de la procédure d'optimisation consiste à se donner un problème géotechnique et à lui associer un modèle numérique. En fonction des sollicitations imposées au modèle, une réponse numérique est calculée. Cette réponse est ensuite comparée aux données expérimentales disponibles. Cette comparaison se traduit par le calcul de l'écart entre les données observées et les valeurs calculées, c'est-à-dire le calcul de la fonction d'erreur (Figure 2.18).

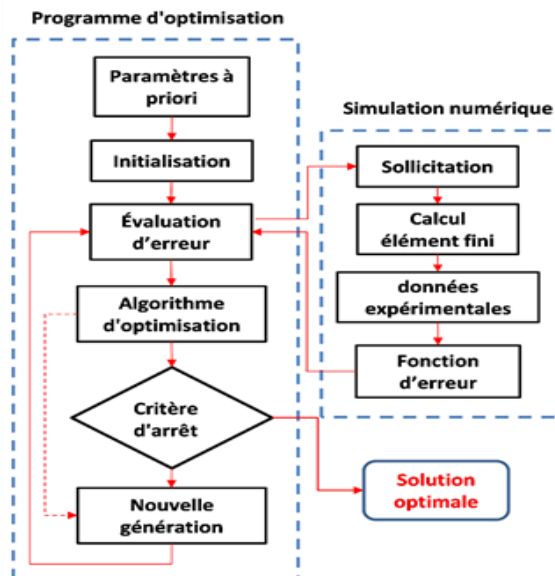


Figure 2.18 Principe d'identification par méthode numérique directe.

Cet écart est ensuite minimisé par un algorithme d'optimisation. De cette optimisation sont déduites de nouvelles valeurs pour les paramètres du modèle constitutif du sol. Le processus se répète jusqu'à ce que l'écart entre les valeurs calculées et les données mesurées soit minimal.

6.4 Algorithmes d'optimisation

L'analyse inverse par méthode numérique directe est liée au concept d'optimisation. Dans la littérature, les méthodes développées pour résoudre des problèmes d'optimisation sont traditionnellement divisées en différentes catégories. Pour Goldberg (1989), elles se divisent principalement en trois types: les méthodes énumératives, les méthodes déterministes et les méthodes stochastiques. Cette revue de la littérature couvre ces trois catégories. Elles seront présentées ci-après.

6.4.1 Méthodes énumératives

Les méthodes énumératives ont un principe simple. Travaillant sur un espace de recherche fini et discrétisé, l'algorithme énumératif permet d'évaluer la fonction à optimiser en chaque point des solutions faisables. Cette exploration complète de l'espace de recherche est comparée par l'utilisateur à l'ensemble des combinaisons possibles sur une marge de variation limitée. Ceci dit, la solution est optimale lorsque la valeur de la fonction d'erreur atteint son minimum. La figure 2.19 présente un exemple typique d'optimisation par une méthode énumérative. Chaque point de la grille correspond à une évaluation de la fonction erreur « F_{err} » pour une combinaison spécifique des paramètres. Lier les points de cette fonction permet de dessiner sa surface caractéristique dans l'espace. Comme le propose Nougier (2001), cette surface caractéristique peut être interprétée comme une représentation de l'altitude d'un point sur un espace donné. Ce type d'exploration exhaustive est essentiellement utilisé aujourd'hui pour tester d'autres méthodes plus élaborées. Cela permet pour des cas simples, de connaître l'allure de la fonction erreur sur le domaine de recherche (Goldberg, 1989). Malgré leurs avantages, ces méthodes présentent des inconvénients majeurs à savoir :

- ❖ Ces méthodes ne sont pas adéquates aux problèmes de grande dimension.
- ❖ Leur méthodologie de travailler sur l'espace de recherche en entier, sans le diviser en des sous-espaces, ne permet pas d'avoir la bonne solution.

6.4.2 Méthodes déterministes

Les méthodes déterministes reposent sur le principe d'exploiter au maximum l'information connue sur un espace de recherche lors de l'estimation d'optimum. En plus, elles utilisent le meilleur chemin pour trouver la solution (Figure 2.20).




Figure 2.19 Représentation de la fonction erreur sur l'espace de recherche (x_1, x_2)




Figure 2.20 Représentation de la fonction erreur sur l'espace de recherche (x_1, x_2) .

Ces méthodes sont habituellement adoptées quand la fonction à optimiser est simple et de forme connue. Les méthodes déterministes sont généralement des méthodes de gradient. Elles n'utilisent aucun concept statistique mais requièrent des hypothèses sur la fonction à optimiser telle que la continuité et la dérivabilité en tout point du domaine de solution. Il existe dans la littérature plusieurs méthodes déterministes dont la méthode du gradient conjugué, celle de la plus grande pente, celle de Newton ainsi que celle de Levenberg-Marquardt ou Quasi-Newton. Malheureusement, les méthodes de gradient sont bien adaptées aux problèmes simples mais pas aux problèmes complexes avec un nombre de paramètres important (Culioli, 1999). Elles évoluent pas à pas selon une direction proche de celle du gradient négatif. La taille du pas peut poser problème, dans la mesure où l'algorithme peut converger trop vite ou trop lentement. De plus, vu que les méthodes de gradient sont trop influencées par leurs dérivées, ce qui pose un problème principal puisqu'en pratique la fonction erreur et l'estimation, qui résultent d'un calcul numérique, ne sont pas forcément dérivables. Ces méthodes de calcul ne sont donc adaptées qu'à une classe limitée de problèmes sans oublier que leur temps d'exécution augmentera exponentiellement en fonction du nombre de variables.

6.4.3 Méthodes stochastiques

Sans aucun doute, la théorie des processus stochastiques et des probabilités reste un des outils les plus importants parmi les outils mathématiques de l'histoire des sciences modernes. Ses procédures sont purement aléatoires, elles explorent et mémorisent le meilleur élément trouvé. Les méthodes stochastiques permettent d'étudier les comportements en moyenne et modélisent les processus de façon probabiliste. La méthode de Monte Carlo est considérée parmi les méthodes de recherche aléatoire les plus simples. Cette dernière consiste à procéder à chaque itération à un tirage aléatoire et indépendant sur l'espace de recherche. Dans chaque itération, la fonction erreur F_{err} est réévaluée de tel sorte que la nouvelle valeur attribuée à F_{err} est comparée à la précédente. Si la nouvelle valeur est meilleure, elle sera enregistrée, ainsi que la solution correspondante et le processus continuera. Sinon la valeur précédente est conservée et la procédure est poursuivie d'une manière itérative jusqu'à l'atteinte des conditions d'arrêt (Figure 2.21). Malheureusement, malgré leur robustesse, ces méthodes sont peu efficaces. C'est pour cette raison, que souvent, ce sont les méthodes pseudo-aléatoires comme les algorithmes génétiques qui sont préférées. Dans l'espace des paramètres codés, le choix aléatoire est utilisé comme outil afin de mener une exploration intelligente. Les procédures pseudo-aléatoires échangent et utilisent les principes de la survie des structures les mieux adaptées afin former un algorithme d'exploration héritant de certaines caractéristiques de l'évolution des espèces. Ainsi, les algorithmes génétiques exploitent efficacement l'information obtenue de l'itération précédente pour spéculer sur la position de nouveaux points à explorer tout en tenant compte de l'amélioration des performances.




Figure 2.21 Exploration de l'espace de recherche

7 Conclusion

Dans ce chapitre, un aperçu général sur les lois de comportement a été donné. Partant des lois les plus simples comme l'élasticité linéaire, qui nécessite deux paramètres pour sa mise en œuvre, jusqu'aux lois les plus complexes qui nécessitent un nombre important de paramètres et la définition de quelques fonctions qui permettent de les suivre dans le temps et dans l'espace. Ensuite, ce sont les codes de calcul utilisés en géotechnique qui ont été décrits. Enfin, une synthèse sur les éléments de base sur l'analyse inverse et les méthodes couramment utilisées a été présentée. Les principales conclusions tirées sont les suivantes :

- ❖ Les lois de comportement sont basées sur un schéma classique. Elles représentent au mieux le comportement des sols. Elles nécessitent la détermination expérimentale des paramètres. Ces paramètres sont ensuite utilisés lors de la justification des ouvrages. Les paramètres doivent être peu nombreux et assez faciles à déterminer, ce qui n'est souvent pas le cas dans la plupart des modèles, plus le nombre des paramètres est important moins le modèle est employé.
- ❖ La nature complexe des sols et la grande variabilité de leurs caractéristiques sur un site donné nécessite une grande prudence dans l'emploi des méthodes de calcul numérique.
- ❖ Les problèmes inverses en géotechnique peuvent généralement être traités comme un problème d'optimisation sur un espace de dimension finie. Tout point dans l'espace de recherche représente un jeu de paramètres qui décrit un ensemble de caractéristiques à identifier. Le but ultime des problèmes d'optimisation est de réduire au minimum la fonction erreur, celle-ci représente l'écart entre les observations et les prédictions théoriques d'un modèle.
- ❖ La fonction erreur est l'indice principal permettant de juger de la représentativité d'un modèle retenu. Les équations obtenues par cette technique d'optimisation dépendent des données introduites et des sites analysés. Par conséquent, l'utilisation pratique reste liée au flair de l'ingénieur géotechnicien responsable du projet et de ses choix.

CHAPITRE 3

APPLICATION DE L'INTELLIGENCE ARTIFICIELLE EN GEOTECHNIQUE

1 Introduction

L'intelligence artificielle constitue l'un des piliers majeurs de l'avancement informatique. Ce terme est introduit par le docteur John McCarthy suite au séminaire organisé à l'université de Dartmouth (USA) en 1956. Dans le cadre d'une étude sur le comportement intelligent des machines et des ordinateurs, il annonça que l'apprentissage est modélisable sous forme d'algorithme puisqu'il est possible de décrire avec précision sa forme et ses caractéristiques (McCarthy et al., 1956). Après cette conférence, beaucoup d'optimisme s'est créé autour de ce nouveau domaine. Depuis le début des années 1990, ces techniques d'intelligence artificielle font leur entrée dans les sciences de l'ingénieur. Elles traitent des problèmes de complexité grandissante dans différents secteurs, comme le traitement d'images, la conception de systèmes de commande et de diagnostic, etc. Les algorithmes de l'intelligence artificielle les plus utilisés visent à résoudre des problèmes qui relèvent généralement des techniques du soft computing tels que la logique floue, les réseaux de neurones artificiels, les méta-heuristiques, etc. Ces derniers comprennent notamment la méthode du recuit simulé, les algorithmes évolutionnaires, la méthode de recherche tabou ainsi que les algorithmes de colonies de fourmis. Ce chapitre est dédié à la définition des notions de base de la théorie des réseaux neurones, les métas heuristiques ainsi que la procédure d'analyse inverse utiles dans les deux chapitres suivants pour des applications en géotechnique.

2 Traitement statistique et analyse de données

2.1 Collecte des données

La collecte des données est l'une des étapes cruciales dans le domaine de l'intelligence artificielle. L'estimation d'une fonction non-linéaire inconnue, avec un échantillon de données limité engendre beaucoup d'erreur. C'est pour cette raison qu'il est préférable d'avoir une quantité de données suffisante, ce qui permet de procéder à un lissage des données de façon à atténuer la variation. Le bon choix des paramètres d'entrée contribue à améliorer considérablement les performances lors de la généralisation. Dans la phase d'apprentissage, nous devons présenter au modèle un ensemble de couples mesure/réponse dans lesquels la mesure présente les variables explicatives, alors que la réponse présente la variable à prédire. Dans la plupart des cas, ces variables sont issues des essais de laboratoire ou in-situ.

2.2 Traitement statistique des données

Après l'achèvement de la collecte des données, un prétraitement de ces dernières doit être effectué afin d'obtenir les entrées du modèle. Il est souvent préférable d'effectuer une analyse des données de manière à déterminer les caractéristiques discriminantes pour différencier et écarter les données aberrantes ou redondantes. Cette détermination impacte directement le temps de simulation ainsi que les performances du système. La description d'un ensemble de variables à travers l'analyse d'un nuage de points évoque les notions de régressions simple, régression multiples et la variance-covariance (Favre, 2004). Ces outils statistiques sont relativement faciles à appliquer et à interpréter dans le cas d'une étude à un nombre réduit de variables. Dans le cas contraire, lorsque le nombre de paramètres est grand, la visualisation et la description statistique des données deviennent difficiles. Du coup, il est préférable d'utiliser dans ce cas, des méthodes descriptives multidimensionnelles telles que les méthodes des composantes principales.

2.2.1 Analyse en composantes principales

L'analyse en composantes principales (ACP) est une méthode d'analyse exploratoire des données, elle a pour objectif de résumer les variables initiales à l'aide d'un petit nombre de nouvelles variables, appelées composantes principales ou facteurs. Les composantes principales obtenues sont des combinaisons linéaires des variables initiales. La répartition des composantes principales sur un nouvel espace de plus faible dimension permet de visualiser l'organisation prépondérante des données. L'analyse en composantes principales peut ainsi révéler des groupes de variables corrélées entre elles, des variables qui s'opposent, pour éventuellement conduire à une typologie de variables. Une analyse en composantes principales débute par une étude préliminaire uni-variée sur chaque paramètre. Le calcul de la moyenne, de l'écart-type, du minimum, du maximum et du coefficient de variation pour chaque variable étudiée donnent des indications sur la répartition des points du nuage dans l'espace des variables. Ensuite, les matrices des corrélations et/ou des covariances sont calculées. De ces matrices sont déduits les valeurs propres et les vecteurs propres correspondants.

Comme illustré sur un exemple de nuage de points (figure 3.1), les vecteurs propres donnent les orientations principales du nuage tandis que les valeurs propres donnent l'inertie du nuage selon chaque direction. Ainsi, les orientations du nuage permettent d'interpréter la sensibilité des paramètres et de trouver des corrélations entre les paramètres. A partir des résultats de l'ACP, des ellipsoïdes peuvent être calculés pour délimiter le nuage. Les axes de l'ellipsoïde sont orientés parallèlement aux vecteurs propres du nuage, la taille des axes est bornée par la valeur maximale de chaque facteur du nuage. Cet ellipsoïde est une approximation au premier ordre du nuage de points.

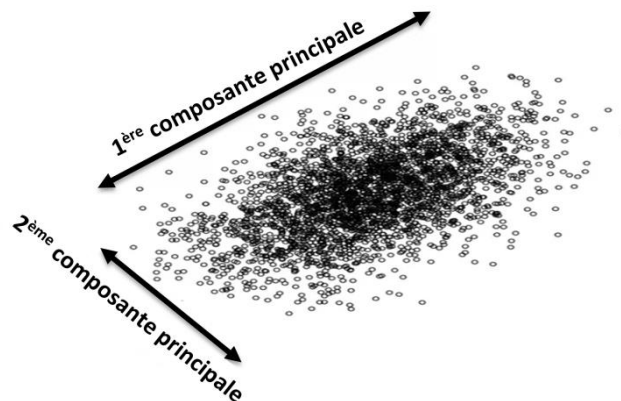


Figure 3.1 Analyse factorielle.

3 Méthodes statistiques de régression

La méthode de régression est un outil qu'on utilise afin de modéliser la relation entre une variable de réponse à prédire et une ou plusieurs variables dites variables indépendantes.

3.1 Régression linéaire simple

Le but de la régression linéaire simple est de déterminer le modèle mathématique qui permet d'expliquer au mieux la variabilité d'une variable quantitative observée dépendante y en fonction d'une seule variable quantitative contrôlée x . Dans le modèle de régression linéaire simple, les autres variables explicatives pertinentes sont négligées, soit intentionnellement pour une simplification de l'analyse, soit que ces variables n'étaient pas mesurables avec une précision acceptable, soit que le coût encouru pour l'acquisition de cette information additionnelle était

prohibitif ou encore simplement à cause d'un manque de planification expérimentale. L'équation générale du modèle est représentée comme suit:

$$y = f(x) + E \times y \quad (3.1)$$

y - variable à expliquer ou réponse, supposée aléatoire.

x - variable explicative, supposée fixe, où E est un terme résiduel aléatoire ou erreur.

3.2 Régression linéaire multiple

La régression linéaire est dite multiple lorsque le modèle mathématique est composé d'au moins deux variables indépendantes quantitatives contrôlées, contrairement au modèle de régression linéaire simple qui ne contient qu'une seule variable indépendante. La régression multiple est un outil de la statistique qui a pour but de bien expliquer la variabilité d'une variable aléatoire y en fonction de plusieurs variables x_1, x_2, x_3, \dots , etc. L'équation de la régression linéaire multiple est en fait la généralisation du modèle de régression simple. Elle s'écrit :

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + E \quad (3.2)$$

y : variable dépendante ou expliquée à caractère aléatoire.

x_1, x_2, \dots, x_p : variables indépendantes ou explicatives mesurées sans erreur ou fixées à des niveaux arbitraires (non aléatoire).

$\beta_1, \beta_2, \dots, \beta_p$ sont les paramètres du modèle (ils sont estimés à l'aide d'un échantillon et la méthode d'estimation sera de nouveau la méthode des moindres carrés);

β_0 est l'ordonnée à l'origine, c'est à dire la valeur de y lorsque toutes les variables x_i sont nulles.

E : erreur commise par le modèle pour chaque valeur de y.

Le modèle de régression linéaire est souvent estimé par la méthode des moindres carrés. On peut aussi par exemple l'estimer par inférence bayésienne ou encore par le maximum de vraisemblance.

3.3 Régression non linéaire

La régression non linéaire est une méthode statistique permettant de trouver un modèle non linéaire d'interaction entre une variable dépendante quantitative observée et un ensemble de variables indépendantes quantitatives contrôlées. La régression non linéaire peut estimer des modèles avec des relations arbitraires entre les variables indépendantes et dépendantes. Ce résultat est obtenu au moyen d'algorithmes d'estimation itératifs. La forme générale du modèle est spécifiée comme suit :

$$y = f(x, \beta) + E \quad (3.3)$$

Où x est un vecteur de variables explicatives, β est un vecteur de dimension p de paramètres inconnus et E est un terme d'erreur.

3.4 Régression non-linéaire multiple

Ce terme désigne une équation permettant de décrire la relation non linéaire entre une variable de réponse continue et plusieurs variables de prédiction qui permettent de prévoir de nouvelles observations. Les formes des courbes non linéaires possibles sont : concave, convexe, à croissance ou décroissance exponentielle, à courbe sigmoïde (S) et asymptotique (Maamri, 2014).

4 L'intelligence artificielle et ses applications dans la géotechnique

Si l'intelligence artificielle a pu conquérir aujourd'hui plusieurs domaines tel que les sciences géotechniques, c'est grâce à l'essor des langages de programmation et le développement exponentiel de la puissance de calcul. Vu la nature complexe et les propriétés physiques multi-variées du sol, les chercheurs en géotechnique devraient choisir la méthode la plus adaptée au sujet traité et à l'état de son développement. Certains chercheurs préfèrent l'utilisation des réseaux de neurones dans leurs travaux, alors que d'autres adoptent les systèmes de calcul évolutionnaires et les métas heuristiques. Dans cette section de cette thèse, une description, présentation et analyse des approches les plus utilisées sera donnée. Nous montrons en particulier l'apport, les avantages et les inconvénients ainsi que les limites de ces approches dans les applications en géotechnique.

4.1 Réseaux neurones artificiels

C'est en 1943 que les deux chercheurs américains McCulloch et Pitts introduisirent la notion du neurone formel (McCulloch et Pitts, 1943). Cette modélisation informatique qui sert comme simulation simplifiée du neurone biologique est devenue l'élément de base des réseaux capables de réaliser des fonctions logiques, arithmétiques et symboliques complexes. En 1949, Hebb (physiologiste américain) a proposé une loi de modification des propriétés des connexions entre les neurones, ce qui explique en partie le conditionnement pavlovien chez l'animal (Hebb, 1949). Les premiers succès de cette méthode ont été présentés par Rosenblatt (1958) qui a construit le premier neuro-ordinateur basé sur le modèle du perceptron. Ce dernier a été utilisé dans le domaine de la reconnaissance des formes. Minsky et Papert (1969) publièrent ensuite leur ouvrage qui met le point sur les limitations théoriques du perceptron, ce qui a impacté négativement le financement de la recherche dans ce domaine. De ce fait, un grand nombre de chercheurs ont tourné le dos aux réseaux de neurones, seuls quelques chercheurs ont continué leurs efforts dont Teuvo Kohonen, Stephen Grossberg, James Anderson et Kunihiko Fukushima. En 1982, c'est au physicien John Hopfield qu'on doit le retour de l'intérêt pour les réseaux de neurones artificiels. Dans un article, cet auteur présente une théorie du fonctionnement ainsi que les possibilités qu'offrent les réseaux de neurones. Il fixe au préalable le comportement à atteindre pour son modèle et construit à partir de là, la structure et la loi d'apprentissage correspondant au résultat escompté (Hopfield, 1982). Ce modèle n'a pas répondu à toutes les attentes et a présenté plusieurs limitations. Néanmoins, les recherches ont été relancées. Ce n'est qu'en 1983 que ces limitations ont été traitées d'une manière satisfaisante, pour la première fois, par la machine de Boltzmann (Hinton et Sejnowski, 1983). Néanmoins, son utilisation en pratique s'avère difficile, à cause de la convergence extrêmement longue de l'algorithme. En 1985, une méthode nommée rétro-propagation de gradient apparaît. C'est un algorithme d'apprentissage adapté aux réseaux de neurones multicouches, suite à laquelle, il est devenu possible de réaliser une fonction non linéaire d'entrée/sortie sur un réseau, en décomposant cette fonction en une suite d'étapes linéairement séparables. Jusqu'à nos jours, les réseaux multicouches et la rétro-propagation de gradient restent les modèles les plus répondus et les plus utilisés par les ingénieurs dans les applications. En fait, les réseaux de neurones sont de plus en plus utilisés dans de nombreux domaines grâce à leurs capacités d'apprentissage et de généralisation. Cependant, l'apprentissage de ces réseaux de neurones artificiels nécessite des exemples réels qui doivent être d'autant plus nombreux que le problème est complexe et que sa topologie est peu structurée. En réalité, la disponibilité des exemples réels pour l'apprentissage pose problème, à cause de leur rareté ou du coût onéreux de la collecte en quantité suffisante.

4.1.1 Eléments de base

Les neurones constituent l'élément de base du système nerveux central (Davallo et al., 1990). Sa structure comporte trois parties principales, le corps cellulaire, les dendrites et l'axone (Figure 3.2).

Le corps cellulaire est celui qui contient le noyau du neurone, il remplit les fonctions vitales nécessaires à la survie de la cellule. Les dendrites, qui forment une espèce d'arborescence autour du corps cellulaire, et les extensions tubulaires du neurone jouent le rôle de récepteurs principaux. L'axone est la fibre nerveuse qui sert à transporter les signaux émis par le neurone. Il se ramifie à son extrémité dans des zones appelées synapses, c'est ces dernières qui permettent la communication avec les autres axones des neurones voisins.




Figure 3.2 La cellule nerveuse et ses composantes.

4.1.2 Modèle de fonctionnement

Pour simplifier, le neurone procède à une sommation des influx nerveux qui lui parviennent des dendrites. Si la sommation dépasse un seuil d'activation, ce dernier transmet un autre influx nerveux via son axone aux autres neurones d'environ. Dans le cas contraire, le neurone reste inactif (Figure 3.3). L'activation peut suivre plusieurs modèles, les plus connues sont la fonction à seuil, la fonction linéaire par morceaux et la fonction sigmoïde. Cette dernière, malgré sa différence avec le modèle binaire du fonctionnement d'un neurone biologique, reste la plus utilisée parmi les modèles actuels (Haykin, 1994).




Figure 3.3 La cellule nerveuse et ces composantes.

4.1.3 Architectures des réseaux

Malgré le fait qu'il existe plusieurs topologies possibles de réseaux de neurones, c'est les schémas standards d'interconnexion ci-dessous qui sont souvent préférés :

- ❖ Réseau monocouche : La structure d'un réseau monocouche impose que les neurones mis en entrée soient entièrement connectés aux autres neurones organisés en sortie par une couche à poids modifiable (Figure 3.4).




Figure 3.4 Structure d'un réseau monocouche.

- ❖ Réseau multicouche : Comme son nom l'indique, les neurones sont arrangés par couche. Chaque couche est composée par les neurones de même niveau de telle façon qu'il n'y ait pas de connexion entre les neurones d'une même couche. Trois types de couches sont distingués : couche d'entrée qui comporte l'ensemble des neurones d'entrée, ceux de sortie font la couche de sortie. Les couches intermédiaires n'ayant aucun contact avec l'extérieur sont appelées les couches cachées (Figure 3.5).




Figure 3.5 Structure d'un réseau multicouche.

- ❖ Réseau à connexions locales : Il s'agit d'une structure multicouche particulière où chaque neurone entretient des connexions plus réduites et localisées avec les neurones de la couche suivante. Les connexions sont donc moins nombreuses que dans le cas d'un réseau multicouche classique (Figure 3.6).




Figure 3.6 Réseau à connexions locales.

- ❖ Réseau à connexions récurrentes : Dans ce type d'architecture, certaines connexions qu'on appelle récurrentes ramènent l'information en arrière par rapport au sens de propagation de l'information, elles sont souvent locales (Figure 3.7).




Figure 3.7 Réseau à connexions récurrentes.

- ❖ Réseau à connexion complète : C'est le type de réseau le plus répandu. Dans ce type de réseau, chaque neurone est connecté à tous les autres neurones du réseau (et à lui-même) (Figure 3.8).




Figure 3.8 Réseau à connexions complète.

4.1.4 Apprentissage des réseaux neurones

Quand il s'agit d'un problème de régression, l'apprentissage consiste à approcher une fonction continue. Alors que dans le cas d'un problème de classification supervisée, cela consiste à déterminer une surface de séparation. Cet apprentissage est procédé en minimisant une fonction, appelée fonction de coût. Celle-ci est calculée en comparant les sorties fournies par la base d'apprentissage avec les sorties du réseau de neurones. On distingue deux grandes types d'algorithmes d'apprentissage : apprentissage supervisé ou non supervisé. La différence entre les deux types repose dans l'objectif voulu de chaque type et cela se reflète sur la forme des exemples d'apprentissages.

4.1.4.1 Apprentissage supervisé

L'apprentissage supervisé consiste à alimenter le réseau de neurones par des exemples labélisés, ce qui permet de calculer les coefficients qui donnent des sorties du système aussi proche des sorties désirées (Figure 3.9). Dans le cas d'une classification, cela se traduit par la définition de la classe d'appartenance de la forme que l'on veut classer, ou la valeur de la fonction que l'on veut approcher dans le cas d'une régression, ou de la sortie du processus que l'on veut modéliser. La plupart des algorithmes d'apprentissage des réseaux de neurones artificiels sont des algorithmes d'optimisation. Ils cherchent à minimiser, par des méthodes d'optimisation non linéaire, une fonction de coût qui constitue une mesure de l'écart entre les réponses du réseau et les réponses réelles désirées. Cette optimisation s'effectue de manière itérative en modifiant les poids en fonction du gradient de la fonction de coût (équation 3.2) :

$$C^k(W) = \sum_{i=1}^p (S_i^k - y_i^k)^2 \quad (3.4)$$

Cette fonction est l'erreur ou distance entre la sortie calculée S^k et la sortie désirée y^k . La totalité des poids de connexion du réseau doit être ajustée en fonction de cette erreur.

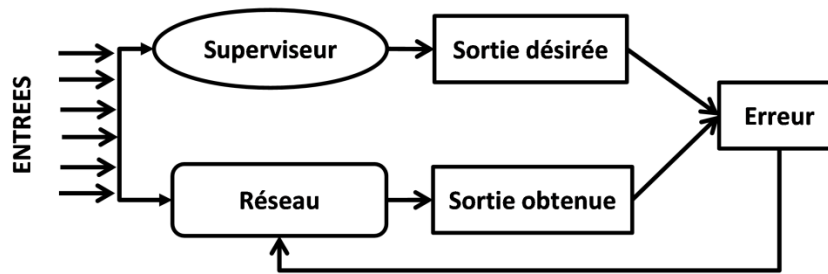


Figure 3.9 Principe d'apprentissage supervisé.

4.1.4.2 Apprentissage non supervisé

Lors de l'apprentissage non supervisé, le modèle ne reçoit pas d'informations lui indiquant les sorties. Il doit découvrir, sans aucune intervention externe, les corrélations qui existent entre les exemples d'apprentissage (Figure 3.10). Alors, un certain degré d'auto-organisation est nécessaire entre les cellules et les connexions. Parmi les réseaux les plus utilisés dans ce cas, il y'a les "cartes auto-organisatrices", les "cartes de Kohonen" ainsi que les "Self-Organizing Map" (SOM). En plus, ce type de réseaux englobe les algorithmes de regroupement connus sous le nom de « clustering » dans le domaine de la reconnaissance de forme (Kohonen et al., 2000).




Figure 3.10 Principe d'apprentissage non supervisé.

4.1.5 Modèles des réseaux de neurones

Il existe plusieurs modèles de réseaux de neurones catégorisés selon leurs architectures, leurs fonctions d'activation et leurs modes d'apprentissage. Nous présentons dans le prochain paragraphe un bref aperçu sur les modèles existant ainsi que leurs modes d'apprentissage. On se focalise surtout sur les trois modèles à savoir : Le perceptron multicouche, le réseau à fonction de base radiale et le modèle de Kohonen.

4.1.5.1 Modèle du perceptron multicouches

Le principe du perceptron fut inventé par le psychologue Frank Rosenblatt à la fin des années 50 (Rosenblatt, 1958). Il représentait sa tentative d'illustrer certaines propriétés fondamentales des systèmes intelligents d'une manière générale. Le réseau du perceptron multicouche (MLP pour multilayer perceptron) est formé de trois couches : Une couche d'entrée (la rétine) fournissant des données à la couche suivante dite intermédiaire. La couche intermédiaire est chargée des calculs, elle fournit la somme des impulsions, parvenu des cellules auxquelles elle est connectée, et répond généralement suivant une loi définie avec un seuil. Elle est connectée à la couche de sortie. La couche de sortie (couche de décision) représente les exemples à mémoriser. Cette dernière couche est la seule capable de renvoyer des signaux à la couche intermédiaire, jusqu'à ce que leurs connexions se stabilisent (figure 3.11).




Figure 3.11 Réseau à connexions complètes.

4.1.5.2 Réseaux à base de fonction radiale

Cette architecture a été introduite par Powell (1985). Le réseau à base de fonction radiale (RBF pour Radial Basis Function) fait partie des réseaux de neurones supervisés. Il est constitué de trois couches, une couche d'entrée qui retransmet les entrées sans distorsion, une seule couche cachée qui contient les neurones RBF qui sont généralement des gaussiennes (Moody et Darken, 1989 ; Poggio et Girosi, 1990) et une couche de sortie dont les neurones sont généralement animés par une fonction d'activation linéaire (figure 3.12). Chaque couche est complètement connectée à la suivante et il n'y a pas de connexions à l'intérieur d'une même couche. Par conséquent, le réseau RBF possède la même architecture que le MLP, la fonction non linéaire de la couche cachée est une gaussienne et les neurones de la couche de sortie n'ont pas d'activité (somme pondérée uniquement).

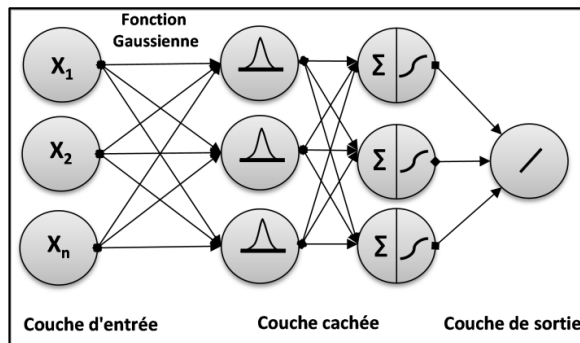


Figure 3.12 Réseau à base de fonction radiale.

4.1.5.3 Modèle de Kohonen

Ce modèle a été présenté par Kohonen (1982) sur la base des constatations biologiques. Les cartes de Kohonen sont réalisées à partir d'un réseau à deux couches, une en entrée et une en sortie. Notons que les neurones de la couche d'entrée sont entièrement connectés à la couche de sortie (Figure 3.13).

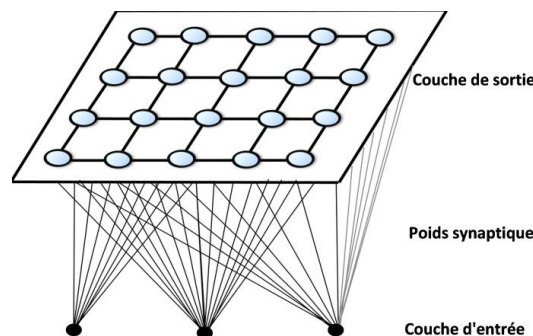


Figure 3.13 Structure cartes de Kohonen.

La carte auto-organisatrice (self organizing map ou SOM) de Kohonen est habituellement composée d'une grille de neurones à deux dimensions. Elle offre la possibilité d'effectuer une réduction de dimensions en projetant les données multidimensionnelles sur une carte à deux ou trois dimensions. Chaque neurone possède donc des voisins dans cet espace. Chaque neurone de la couche de sortie possède des connexions latérales récurrentes dans sa couche (le neurone inhibe les neurones éloignés et laisse agir les neurones voisins). Ce type de réseau de neurone est essentiellement utilisé dans la classification par l'intermédiaire d'un algorithme de Kohonen à apprentissage non supervisé.

4.1.6 Domaine d'application

Les réseaux de neurones sont caractérisés par leur grande robustesse et leur tolérance aux informations bruitées ou incomplètes. Ces caractéristiques leurs ont permis d'être au cœur d'une large variété d'applications et d'être de plus en plus présents dans différents domaines de la géotechnique et de la mécanique de sol. Pour avoir une vision globale sur l'utilisation des réseaux de neurones artificiels dans ces domaines, il est nécessaire de se référer aux travaux de Shahin et ses collaborateurs (Shahin et al., 2002; Shahin et al., 2009). A travers leurs travaux, ces auteurs ont prouvé l'utilité et la précision des réseaux de neurones artificiels dans le domaine de la prédiction en géotechnique malgré la grande variabilité des paramètres des sols et leurs comportements complexes. Au cours de la dernière décennie, de nombreux travaux ayant trait à l'application des réseaux de neurones dans ce domaine ont été publiés. En 2010, une corrélation a été proposée par Patel et Desai entre la masse volumique sèche optimale, l'indice de plasticité, le CBR_{imm} des sols alluviaux ainsi que la teneur en eau optimale Proctor (Patel et Desai, 2010). Dans une étude menée par Roy et al (2011), une année plus tard, d'autres corrélations ont été proposées entre le CBR_{imm} et les différentes propriétés des sols étudiés. Sidarta et Ghaboussi (1998) se sont intéressés à la modélisation des matériaux en géotechniques en adoptant de nouveaux tests qui incluent un état de contrainte non-uniforme. Ils ont montré aussi qu'il est possible d'extraire d'un seul test plus d'informations qu'à partir de plusieurs tests traditionnels. Hashash et al. (2006) ont proposé d'appliquer les réseaux de neurones dans l'identification des caractéristiques du sol à partir des étapes de la construction d'une excavation. Leur objectif était de trouver une formulation de la matrice de rigidité reliant le tenseur d'entrée au tenseur de sortie. Ils ont cherché ainsi à définir la loi du comportement du sol dans un contexte particulier. De même pour Yamagami et al. (1997) qui se sont intéressés à l'étude de la stabilité des pentes en utilisant les réseaux de neurones. Dans la même optique, Pernot et Lamarque (1999) ont utilisé les réseaux de neurones dans l'étude du comportement du sol sur des essais de laboratoire. Hashash et al (2004) ont proposé d'utiliser les réseaux de neurones dans la modélisation des éléments finis traitant les problèmes de frontière. Grâce à la capacité d'apprentissage continue des réseaux de neurones, et vu la facilité d'implémentation dans l'analyse par éléments finis, leur application s'est avérée beaucoup plus avantageuse par rapport à l'utilisation des modèles élastoplastiques. Finalement, tous ces avantages font que les réseaux de neurones artificiels seront de plus en plus utilisés pour résoudre différents types de problèmes géotechniques.

4.2 Méthodes d'optimisation

Dans les différents secteurs de la recherche opérationnelle, les ingénieurs sont régulièrement confrontés à des problèmes technologiques de complexité grandissante. Dans une grande partie des cas, le problème à résoudre peut-être exprimé sous la forme générale d'un problème d'optimisation, dans lequel une fonction objectif définie est à minimiser par rapport à tous les paramètres

concernés. Il existe plusieurs méthodes d'optimisation dites classiques pour résoudre de tels problèmes. Ces techniques sont applicables lorsque certaines conditions mathématiques sont satisfaites. Malheureusement, les situations réelles rencontrées sont beaucoup plus complexes, ce qui rend ces méthodes inapplicables dans le cas où la fonction objectif est par exemple non linéaire, ou quand celle-ci ne peut pas s'exprimer analytiquement en fonction des paramètres concernés. Dans d'autres cas, le problème peut exiger la considération simultanée de plusieurs objectifs contradictoires (Collette et Siarry, 2011). L'arrivée d'une nouvelle classe de méthodes, nommée méta-heuristiques, présente une réconciliation des deux domaines. En effet, celles-ci s'appliquent à toutes sortes de problèmes combinés. Elles peuvent s'adapter également aux problèmes continus. Les méthodes méta-heuristiques englobent entre autres, la méthode du recuit simulé, les algorithmes génétiques, la méthode de recherche tabou, les algorithmes de colonies de fourmis ainsi que l'algorithme des essais.

4.2.1 Problème d'optimisation

Un problème dit d'optimisation peut être défini comme étant la recherche de la solution x^* dans un ensemble S de solutions possibles, appelé espace de recherche, qui rend minimale ou maximale une fonction mesurant la qualité de cette solution. Cette dernière est appelée fonction objectif ou fonction coût. La résolution d'un problème d'optimisation consiste donc à rechercher l'optimum global, qui est considéré comme la meilleure solution. Cependant, il peut exister des solutions intermédiaires qui sont également des optimums, dits locaux car ils le sont uniquement pour un sous-espace restreint de l'espace de recherche. Cette notion est illustrée dans la figure 3.14.




Figure 3.14 Différence entre un optimum global et des optima locaux.

4.2.2 Classification des méthodes de résolution des problèmes

Généralement, la résolution d'un problème d'optimisation passe par des méthodes d'optimisation dont la classification est illustrée dans la figure 3.15. On distingue d'abord l'optimisation continue de l'optimisation discrète (ou combinatoire). Cette première distinction est basée sur la nature des espaces dans lesquels les variables de décision prennent leurs valeurs, c'est la dichotomie (discret-continu) bien connue en Mathématiques et qui conditionne évidemment les possibilités de recourir à certaines méthodes. Pour l'optimisation continue, le cas linéaire, qui relève notamment de la programmation linéaire, est généralement séparé du cas non linéaire dont le cadre de l'optimisation est relativement complexe. Quant aux problèmes d'optimisation combinatoire de taille raisonnable, les méthodes exactes peuvent trouver des solutions optimales. Ces méthodes explorent de façon systématique l'espace des combinaisons jusqu'à trouver une solution optimale. Or, le plus souvent, quand la taille du problème augmente, le nombre des valeurs prises par l'ensemble des variables explose, ce qui exclut l'énumération exhaustive comme option de solution.

Afin de tenter de contenir l'explosion combinatoire, ces approches structurent l'espace des combinaisons en arbre et utilisent des techniques d'élagage, pour réduire cet espace, et des heuristiques, pour déterminer l'ordre dans lequel il est exploré. Cependant, ces techniques ne réduisent pas toujours la combinaison d'une manière suffisante pour que le problème soit résolu en un temps acceptable.

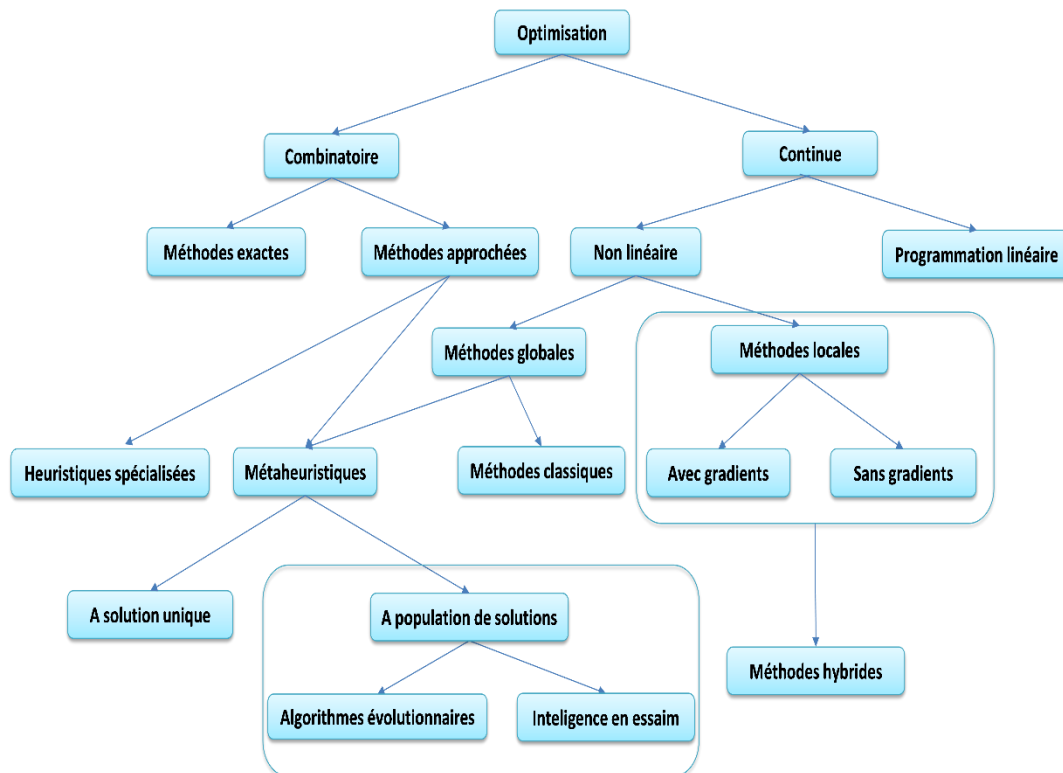


Figure 3.15 Classification des méthodes d'optimisation (Dréo et al., 2003).

4.3 Les approches méta-heuristiques pour l'optimisation mono-objectif

Comme il a été déjà défini précédemment, les méta-heuristiques sont une catégorie d'algorithmes d'optimisation qui vise à résoudre des problèmes d'optimisation dont la solution n'admet pas une approche conventionnelle efficace. Elles sont caractérisées par leurs natures stochastiques et sont généralement inspirées de certains phénomènes naturels (Yang, 2010). Récemment, ce type d'approches est devenu parmi les techniques d'optimisation les plus étudiées. Cela n'est pas dû seulement à leurs aptitudes à gérer à la fois des variables discrètes et des variables continues, mais aussi à leurs capacités de résoudre les différents problèmes d'optimisation dont la complexité ne permet pas chercher toutes les solutions possibles. Les méta-heuristiques restent donc un choix prometteur dans la recherche des solutions efficaces, réalisables dans des délais acceptables avec peu d'informations sur l'espace de recherche (Yang, 2008). Dans ce qui suit, nous allons nous focaliser sur l'étude des approches méta-heuristiques consacrées à l'optimisation mono-objectif et dont le problème d'optimisation n'est défini que par une fonction objectif à unique résoudre. Cette catégorie d'optimisation regroupe deux classes fondamentales, les méta-heuristiques à solution unique et les méta-heuristiques à population de solutions, ainsi que leurs dérivées comme l'illustre la figure 3.16.

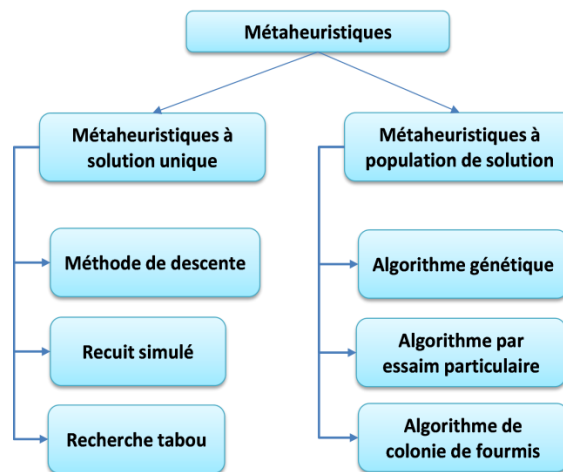


Figure 3.16 Classification des méta-heuristiques.

Ce qui différencie les méta-heuristiques des approches classiques est la façon avec laquelle le déplacement s’effectue dans l'espace des solutions entre deux étapes successives. Dans ce cas d’étude, le bon choix des stratégies et des mécanismes de mouvement devient crucial afin d’avancer d’une manière plus fiable vers la solution. Cela a conduit les développeurs à proposer une synergie d'algorithmes d'optimisation. Dans cette optique, le tableau 3.1 ci-dessous présente les méthodes méta-heuristiques les plus rencontrées dans la littérature avec leurs développeurs, leurs références originales ainsi que leurs phénomènes d’inspiration.

Tableau 3.1 Références des méta-heuristiques et leurs inspirations Méta-heuristiques.

Références	Approches	Phénomènes d’inspiration
Holland (1975)	Algorithmes génétiques	Principe de la sélection naturelle et de l’évolution des espèces
Kirkpatrick et al. (1983)	Recuit simulé	Phénomène physique du recuit
Glover (1986)	Recherche tabou	Mémoire humaine
Farmer et al. (1986)	Système immunitaire artificiel	Système immunitaire naturel
Feo et Resende (1989)	Recherche adaptative gloutonne et randomisée	Mécanisme de construction par étape stochastique
Dorigo (1996)	Colonies de fourmis	Comportement de fourmis réelles
Fleury (1993)	Algorithme de kangourou	Phénomène physique du recuit et le comportement des kangourous
Eberhart et Kennedy (1995)	Essaims particuliers	Comportements sociaux des animaux
Geem et al. (2001)	Recherche d'harmonie	Processus d'improvisation des musiciens
Birbil et Fang (2003)	L’électromagnétisme	Théorie d’électromagnétisme
Karaboga (2005)	Colonies d'abeilles	Comportement d’un essaim d’abeilles
Yang (2008)	Algorithme luciole	Le comportement clignotant des lucioles (famille d’insecte)
Yang et Deb (2009)	Recherche -Cuckool	Parasitisme des oiseaux
Yang (2010)	Algorithme de chauve-souris	Comportement d’écholocation des microchiroptères
Kaveh et Talatahari (2010)	Recherche du système chargé	Théorie de la physique et de la mécanique

4.4 Méta-heuristiques à solution unique

Le principe de ce type de méta-heuristiques, dites aussi méthodes de recherche locale ou de trajectoires, est de faire évoluer une seule solution dans l’espace de recherche. Elles démarrent par une première solution unique et à chaque itération, la solution prend une nouvelle valeur dans son voisinage pour améliorer la fonction objectif. La famille des méta-heuristiques est très large,

néanmoins certaines d'entre-elles comme la méthode de descente, la méthode du recuit simulé ou la méthode de recherche tabou sont plus connues. C'est ces dernières qui sont présentées dans les paragraphes suivants.

4.4.1 Méthode de descente

La méthode de descente (DM : Descent Méthode) ou la méthode de recherche locale (LS : Local Search) est l'un des algorithmes d'optimisation les plus utilisés vue sa simplicité. Cette méthode progresse en démarrant d'une solution initiale S en choisissant à chaque itération la meilleure solution voisine de la solution courante. Cette opération se répète tant que la valeur de la fonction objectif diminue. Le critère d'arrêt est atteint lorsqu'aucune amélioration de la solution courante S n'est plus possible. L'inconvénient majeur de la méthode de descente est qu'elle ne présente aucune forme de diversification dans son processus de recherche, en plus d'être trompeuse dans le premier optimum local trouvé.

4.4.2 Recuit simulé

Comme son nom l'indique, cette méthode de recherche est inspirée du phénomène physique du recuit, utilisé depuis longtemps par les métallurgistes (Tableau 3.2). Ses principes ont été proposés pour la première fois par Kirkpatrick et al. (1983). Pour obtenir un alliage sans défaut, des cycles de réchauffage (ou de recuit) et de refroidissement lent des métaux sont effectués, ceci permet d'obtenir une structure cristalline solide. Cette méthode utilise cette stratégie pour éviter les minimas locaux. La simplicité et l'efficacité de la méthode à résoudre les problèmes d'optimisation combinatoire explique l'impact majeur qu'elle a eu dans le domaine de la recherche heuristique (Talbi, 2009). Bien que cette méthode a été destinée essentiellement pour résoudre des problèmes d'optimisation discrets, son utilisation a été élargie aux problèmes d'optimisation continus. A l'image d'un système physique (Voir tableau 3.2), la méthode du recuit simulé exploite l'algorithme de Métro-polis qui permet de simuler l'évolution d'un système physique instable vers un état d'équilibre stable avec la variable T fixe.

Tableau 3.2 Analogie entre un problème d'optimisation et un système physique (Dréo et al., 2003).

Problème d'optimisation	Système physique
Solution	État du système
Fonction objectif	Énergie libre (E)
Paramètres du problème	Coordonnées des particules
Trouver une bonne configuration	Trouver les états à basse énergie
Optimum global	État stable ordonné
Optimum local	État métastable
Recherche locale	Trempe rapide
Le paramètre T	La température

Le recuit simulé est avantageux en comparaison avec d'autres méthodes pour des raisons de simplicité et de la qualité des solutions obtenues. Par contre, l'inconvénient majeur de cette méthode réside dans le choix des paramètres, ce qui peut induire l'algorithme à converger vers un minimum local. De plus, le temps de calcul peut devenir très significatif.

4.4.3 Recherche tabou

La méta-heuristique tabou a été formalisée par Glover en 1986 (Glover, 1986) en s'inspirant de la mémoire humaine. Cette méta-heuristique s'est avérée efficace face à des problèmes discret ou continu d'optimisation. Elle a gagné en popularité et est devenue très classique en optimisation combinatoire grâce aux succès qu'elle a eu, elle a été testée avec succès sur des problèmes

géotechniques (Aruga, 2005; Ming Hsu et al., 2006; Tan et al., 2008; Moutsopoulos et al., 2017). La méthode opère sur un échantillon de solutions et utilise la notion de mémoire pour éviter d'être piégé dans des optima locaux. Le procédé permet à travers une séquence de mouvements d'exploration sur l'espace de recherche de se déplacer d'une solution vers une autre par observation du voisinage de la solution de départ afin d'atteindre l'optimum en remplaçant à chaque itération la solution courante par la meilleure solution trouvée dans son voisinage.

4.5 Méta-heuristiques à base de population de solutions

A la différence des méthodes de recherche locale, les méthodes à base de population de solution permettent de déterminer un ensemble de solution à chaque itération. Cette catégorie englobe deux familles de méta-heuristique, la première inspirée de la théorie de l'évolution est celle des algorithmes évolutionnaires. La deuxième famille est celle des algorithmes d'intelligence en essaim, elle est inspirée de la biologie.

4.5.1 Algorithmes évolutionnaires

Cette famille des algorithmes d'optimisation a été développée dans les années 50, le principe est inspiré de la sélection naturelle des espèces de Darwin (1858). Ces algorithmes sont parmi les plus utilisés en industrie grâce à leur adaptation aux problèmes d'optimisation qui manipulent de nombreux paramètres.

4.5.1.1 L'algorithme génétique

Ce type d'algorithmes qui fait partie de la classe des algorithmes évolutionnaires, est le plus populaire et le plus utilisé de sa classe (Goldberg, 1989). En s'inspirant des théories génétiques de l'évolution naturelle, John Holland l'a développé 1975. Il repose donc sur une population d'individus, où chacun représente une solution du problème. Par analogie avec la biologie, les algorithmes évolutionnaires se base sur un modèle itératif commun dans lequel chaque population parents donne naissance à une génération enfants en utilisant quatre principales opérateurs génétiques qui constituent son fondement, à savoir la sélection, le croisement, la mutation et le remplacement (Figure 3.17) (Sastry et al., 2005).




Figure 3.17 Terminologie de l'algorithme génétique.

- ❖ L'opération de sélection : Ce processus de sélection se base sur les valeurs de la fonction objective pour choisir les individus les plus adaptés à la reproduction, sachant que ces derniers sont les individus qui ont les valeurs les plus faibles de cette fonction (Figure 3.18).




Figure 3.18 Processus de sélection.

- ❖ L'opération de croisement : C'est un mécanisme permettant la combinaison des caractéristiques des individus parents pour produire la nouvelle génération. Sur la figure 3.19 ci-dessous est illustré le principe de ces enjambements qui peuvent être simples ou multiples. Dans le premier cas du processus, le point de croisement identique des deux chaînes parents est sélectionné aléatoirement en échangeant les parties situées à droite. A la différence du premier cas, le processus de croisement multiple utilise deux points de croisement à la place d'un seul, avec échange des parties situées entre eux.




Figure 3.19 Le processus de croisement.

- ❖ L'opérateur de mutation : Comme dans la biologie, cette procédure consiste à modifier aléatoirement un gène de l'individu de l'enfant après le croisement. Parmi les exemples basiques de ce type d'opérateur, on présente la mutation binaire dans la figure 3.20 qui explique qu'un bit « 1 » est échangé aléatoirement par « 0 » et vice versa.




Figure 3.20 Processus de mutation.

La convergence plus au moins rapidement à l'optimum global de l'algorithme génétique dépend de plusieurs paramètres dont la taille de la population, le type et probabilité de croisement, le mécanisme de sélection, la probabilité de mutation ainsi que la stratégie de remplacement.

4.5.1.2 Programmation génétique multi-gènes (MGGP)

La dernière version de la programmation génétique a été proposée par Alavi et Gandomi (2011), il s'agit de la programmation génétique multi-gènes (MGGP). Cette version a montré certaines

performances quand elle a été appliquée à des problèmes techniques complexes. Des études comparatives entre la MGGP et d'autres algorithmes d'apprentissage ont permis de démontrer la grande robustesse de celle-ci face à des problèmes avec des données manquantes, ou encore sa performance sur des problèmes dont la forme de la solution est méconnue (Kobashigawa et al., 2009).

En plus, la MGGP est capable de proposer des équations mathématiques concrètes que les réseaux de neurones ou d'autres techniques ne peuvent pas le faire (Mohammadi Bayazidi et al. 2014). Généralement, les structures évoluées par la programmation génétique sont représentées par l'une des trois formes suivantes : sous forme linéaire, sous forme d'arbre ou sous forme de graphe. Dans notre application, c'est la structure sous forme d'arbre comme présenté sur la figure 3.21, appelé « arbre syntaxique », qui sera utilisée.

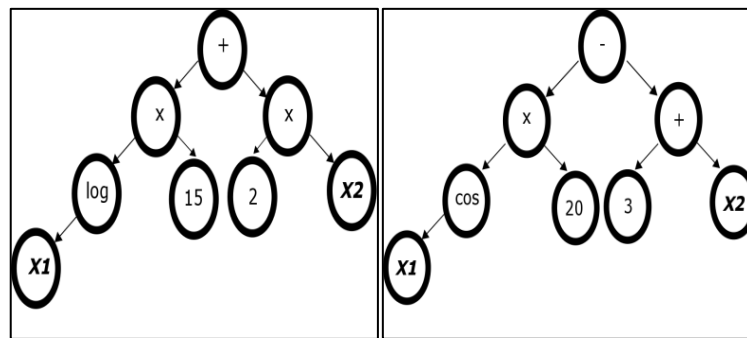


Figure 3.21 Schéma d'un arbre syntaxique.

Dans le cadre de la programmation génétique, à partir d'une première population de programmes générée de manière stochastique et à l'aide d'opérateurs inspirés librement du darwinisme, la programmation génétique fait évoluer cette population de manière stochastique. Par réitération de ce processus, le programme fait converger la population vers la solution du problème. La figure 3.22 donne une idée du fonctionnement général de la programmation génétique.

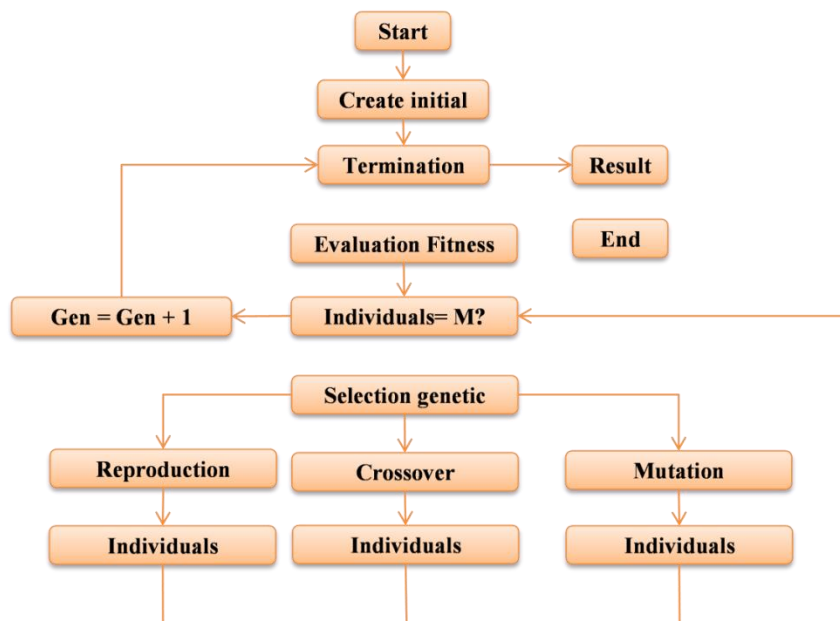


Figure 3.22 L'organigramme d'un algorithme évolutionnaire.

4.5.2 Algorithmes d'intelligence en essaim

L'intelligence en essaim est une nouvelle approche de résolution des problèmes d'optimisation complexes en s'inspirant des comportements sociaux des insectes et d'autres animaux. Les

algorithmes d'intelligence en essaim les plus connus sont : les algorithmes de colonies de fourmis et les algorithmes de colonies d'abeilles.

4.5.2.1 Algorithme de colonies de fourmis

A l'instar de tous les êtres vivants constituant les écosystèmes terrestres, les fourmis subissent les mêmes contraintes et vivent les mêmes conditions, elles doivent se nourrir, se loger, se défendre et se reproduire. Cependant, ce qui est caractéristique chez les fourmis, c'est leur capacité d'agir collectivement pour résoudre ces problématiques quotidiennes. Leurs systèmes d'action reposent sur le partage du travail pratiquement pour toutes les tâches, de la construction du nid au partage d'informations lors de la recherche de la nourriture, sans oublier leur capacité de s'adapter à leur environnement lors de déplacement par exemple. En effet, c'est pour cette raison que les chercheurs ont pensé à convertir les modèles du comportement collectif des fourmis en méthodes pour résoudre les divers problèmes d'optimisation (Siarry et al. 2014). Parmi ces méthodes, il y'a la méthode ACO (Ant Colony Optimization) qui a été introduite par Dorigo (1996). Ce dernier s'est inspiré du génie collectif des fourmis qui optimisent le chemin parcouru entre le nid et la source de nourriture. En effet, chaque fourmi marque son chemin en déposant une certaine quantité de phéromones (substance chimique), dans le but de marquer une trace attirante (odorante) pour que les autres fourmis suivent le chemin le plus court. (Figure 3.23). Ce mode de communication indirecte est appelée « stigmergie».




Figure 3.23 Système d'action des colonies de fourmis.

4.5.2.2 Essaims particuliers (Particle Swarm Optimization [PSO])

Les essaim particuliers sont une famille des méta-heuristiques qui s'inspire à l'origine du monde du vivant surtout du comportement social des animaux évoluant en essaim pour atteindre un objectif donné dans un espace de recherche telle que les nuées d'oiseaux, les bancs de poissons et les essaim d'abeilles (Reynolds, 1987; Heppner et Grenander, 1990). L'algorithme essaim particuliers, a été originellement proposé par Kennedy et Eberhart (1995). Cette méta-heuristiques est basée sur le partage social de l'information entre les membres d'un groupe assurant ainsi un avantage évolutif (Kennedy, 1999). Le groupe possède une hiérarchie globale et une collaboration entre ses individus ce qui permet de résoudre des problèmes complexes. La collaboration des individus permet de tirer des avantages de cette population et surmonter le fait que chaque individu a une intelligence limitée. La méthode d'optimisation par essaim particulier est considérée comme l'inspiration pour un nouveau domaine de recherche appelé intelligence en essaim. Elle a été développée pour résoudre des problèmes continus, mais plusieurs auteurs l'ont adapté aux cas discrets (Handayanto et al., 2017; Bourouis et al., 2020; Kardani et al., 2020). C'est une technique très générale, mais qui reste très appliquée à plusieurs problèmes comme le montre les travaux présentés par Zheng et al (2017), Handayanto et al., (2017) et Bui et al. (2018). Afin de mieux

comprendre cette similitude avec le monde réel, prenons par exemple un groupe d'oiseaux, chaque individu de cette population cherche la nourriture dans l'espace de recherche du problème d'une manière aléatoire sans aucune information sur l'endroit de la nourriture. La seule donnée disponible, c'est la distance qu'il y a entre eux.




Figure 3.24 Principe du déplacement d'une particule.

Le but est de suivre l'oiseau le plus proche de la nourriture. Un algorithme d'essaims particulaires se base sur le même principe qui est facile à mettre en œuvre, il est initialisé avec une population (essaim) de solutions potentielles aléatoires (particules). Chaque particule possède une distance par rapport à la solution souhaitée afin d'actualiser les meilleures positions connues. A chaque itération, cette particule se déplace selon une vitesse. Son déplacement dans l'espace de recherche est guidé par sa meilleure solution et la meilleure solution obtenue dans son voisinage (Figure 3.24). Notons qu'à chaque itération de l'algorithme, la nouvelle vitesse et la nouvelle position de chaque particule sont recalculées. La vitesse de déplacement dépend de plusieurs éléments qui pondèrent les tendances de la particule. Le premier facteur est l'écart par rapport à leurs meilleures positions connues et à celle de leurs voisins pondérées par des coefficients de confiance notés respectivement c_1 et c_2 (c_1 est un coefficient cognitif et c_2 est un coefficient social). Le second est le facteur de vitesse actuelle pondérée par un coefficient d'inertie w . En fait, dans les essaims particulaires, au lieu de travailler avec des opérateurs génétiques plus traditionnels, chaque particule ajuste son vol en fonction de sa propre expérience et celle de ses compagnons. Ces dernières années, plusieurs variantes de l'algorithme des essaims particulaires ont été proposées et leurs paramètres réglés, ce qui a conduit au développement des performances de cette méthode en déterminant ses coefficients à l'aide d'une étude de convergence et en réglant ses principales variables aléatoires.

4.6 Hybridation des méta-heuristiques

L'intérêt pour ce concept d'hybridation ne cesse d'augmenter dans le domaine de l'optimisation grâce à la qualité des résultats obtenus par ces algorithmes. Faisant partie de la classe des méthodes de recherche locale, basés sur l'intensification, ou du groupe de la recherche globale, reposant sur la diversification, l'objectif ultime reste celui de combiner les avantages et les inconvénients de chacune d'elles afin de trouver un bon compromis (Talbi, 2009). On distingue deux catégories de classification des méta-heuristiques hybrides, une hybridation hiérarchique et une hybridation plate.

4.6.1 Classification hiérarchique

La classification hiérarchique en elle-même se divise en deux types, l'hybridation est dite de bas niveau lorsque la fonction d'une méta-heuristique est remplacée par un autre méta-heuristique. On l'appelle hybridation de haut niveau quand elle utilise des méta-heuristiques autonomes qui n'ont

pas de relation directe dans leur fonctionnement interne. Une autre subdivision de ces deux types se pose selon le mode d'exécution des méta-heuristiques. Lorsque ces dernières sont exécutées séquentiellement, l'hybridation est dite en relais, dans ce cas on utilise la sortie de la première méta-heuristique comme entrée de la seconde. L'hybridation est dite en coévolution lorsqu'on travaille dans un modèle où les agents coopèrent en parallèle pour explorer les différentes zones de l'espace de recherche. En résumant, la hiérarchisation de l'hybridation a fait ressortir quatre classes distinguées comme suit : bas niveau en relais, bas niveau en coévolution, haut niveau en relais et haut niveau en coévolution.

4.6.1.1 Hybridation de bas niveau en relais

L'hybridation de bas niveau en relais est un algorithme qui intègre une méta-heuristique dans une méta-heuristique à solution unique. Cette catégorie regroupe généralement les méta-heuristiques à solution unique, à l'instar de l'intégration de la recherche locale (LS) dans la méthode du recuit simulé.

4.6.1.2 Hybridation de bas niveau en coévolution

C'est une hybridation qui consiste à intégrer une méta-heuristique à solution unique basée sur l'exploitation dans une méta-heuristique qui opère avec une population de solution basée sur l'exploration. Ces dernières se distinguent par l'exploration de zones plus vastes contrairement aux algorithmes à solution unique, qui sont beaucoup plus puissants dans exploitation, ce qui permet leurs applications pour des problèmes d'optimisation très variés. L'algorithme évolutionnaire est parmi les bons exemples de cette combinaison, où l'opérateur de mutation est substitué soit par la méthode de descente, par la méthode du recuit simulé ou bien par la méthode de recherche tabou.

4.6.1.3 L'hybridation de haut niveau en relais

Cette catégorie englobe par définition l'utilisation des méta-heuristiques autonomes d'une façon séquentielle, autrement dit la sortie de la première méthode est initialisée pour la méthode suivante. Cette hybridation permet l'amélioration des solutions de l'algorithme à population de solution en les utilisant comme des solutions initiales dans un algorithme à solution unique. C'est une combinaison très efficace vu que les méta-heuristiques à population de solution permettent la localisation rapide des régions les plus vastes et complexes, en facilitant par la suite au méta-heuristique à solution unique de trouver le meilleur optimum.

4.6.1.4 Hybridation de haut niveau en coévolution

Comme son nom l'indique, dans cette hybridation, l'ensemble des agents effectuent la recherche d'une façon parallèle et coopèrent par la suite pour trouver l'optimum d'un problème.

4.6.2 Application des méta-heuristiques dans la géotechnique

La prédiction du tassement à long terme est un exemple typique de l'optimisation combinatoire complexe et dont la solution nécessite de faire recours au concept des méta-heuristiques pour assurer l'estimation. De nombreux auteurs ont utilisé les méta-heuristiques pour la résolution des problèmes de géotechnique. On citera les travaux de Todoroff et al (1998). Les auteurs ont adopté un algorithme génétique dans le développement de leur modèle pour identifier les profils hydriques du sol en vue d'améliorer la maîtrise des risques. Kalatehjari et al. (2014), dans leurs travaux, ont cherché à détecter et à surveiller les mouvements du sol en surface et en profondeur. Pour localiser l'emplacement des surfaces du glissement critique, les auteurs ont choisi d'utiliser un algorithme d'optimisation par essais particuliers puisque ce phénomène réagit aux risques du minimum

local. Le procédé s'est avéré rapide et efficace. La programmation génétique a aussi été appliquée à d'autres problématiques comme les corrélations (Javadi et al. 2006; Bourouis et al. 2019) ou l'estimation des tassements par analyse de séquence (Rezania et Javadi, 2007). Le tableau 3.3 résume les principales contributions trouvées dans la littérature sur l'identification, la prédiction et l'optimisation à base de méta-heuristiques dans le domaine géotechnique.

Tableau 3.3 l'utilisation des méta-heuristiques.

Auteur	Approche	Application
Todoroff et al. (1998)	AG	Identification de profils hydriques du sol
McCombie et Wilkinson (2002)	AG	Stabilité des pentes
Kuok et al. (2010)	PSO-NN	Modélisation des précipitations quotidiennes
Kalatehjari et al. (2014)	PSO	Détermination de l'emplacement de la surface du glissement critique
Chen et al. (2015)	PSO	Optimisation du programme standard d'analyse des glissements de terrain (STABL)
Gordan et al. (2016)	PSO-NN	Stabilité des pentes
Pedro et al.(2017)	AG	Identification des paramètres d'un modèle constitutif avancés (SSCM) utilisés pour simuler l'excavation.
Zhen et al. (2017)	AG	Identification des paramètres du modèle élasto-viscoplastique à partir des résultats d'essais triaxiaux
Zhang et al. (2017)	AG - RMSA	Identification des paramètres du modèle constitutif avancés (SSCM) utilisés pour simuler une excavation profonde.
Shen et Chen (2017)	PSO	Stabilité des pentes
Armaghani et al. (2017)	PSO-NN	Estimation de la capacité portante ultime des pieux ancrés dans la roche
Kardani et al. (2020)	PG-PSO	Estimation de la capacité portante ultime des pieux ancrés dans un sol non cohésif

5 Apprentissage profond

Les techniques d'apprentissage profond (deep learning) ont rencontré un succès remarquable dans les années 2010, pourtant elles sont anciennes. Leur essor doit beaucoup à la disponibilité de données massives et à l'amélioration des vitesses de calcul des processeurs. En apprentissage profond, qui repose donc sur des réseaux de neurones profonds (deep neural networks), on peut distinguer les techniques selon lesquelles les réseaux de neurones sont organisés. Les réseaux de neurones peuvent être en couches, tel le Perceptron, les Perceptrons multicouches et les architectures profondes (plusieurs dizaines ou centaines de couches), dans lesquels chaque neurone d'une couche est connecté à tous les neurones des couches précédentes et suivantes (c'est la structure la plus fréquente). Les réseaux de neurones peuvent aussi être totalement interconnectés, dans lesquels tous les neurones sont connectés les uns aux autres. Ils peuvent aussi être récurrents ou à convolution. Ces deux dernières technologies font l'objet d'investigations particulièrement poussées et d'applications de plus en plus nombreuses depuis quelques années. Les réseaux neuronaux récurrents (RNN) permettent de prendre en compte le contexte et de traiter des séquences avec des réseaux de neurones. Au sein de ces réseaux neuronaux récurrents, on relève les architectures MARNN (Réseaux neuronaux récurrents à mémoire augmentée) et les architectures LSTM (Long Short Term Memory) qui forment un chantier de recherche prioritaire pour les chercheurs de Google (Deep Mind en particulier), Baidu, Apple, Microsoft et Facebook. Leur utilisation pour la traduction, la production de légendes pour les images et les systèmes de dialogues

visé à répondre à la question de la capacité à apprendre des tâches qui impliquent non seulement d'apprendre à se représenter le monde, mais aussi à se remémorer, à raisonner, à prédire et à planifier.

5.1 Quelques algorithmes de Deep Learning

Il existe différents algorithmes de « Deep Learning ». Nous pouvons citer :

- ❖ **Les réseaux de neurones profonds** : Ces réseaux sont similaires aux réseaux du perceptron multicouche (MLP) mais avec plus de couches cachées. L'augmentation du nombre de couches permet à un réseau de neurones de détecter les légères variations du modèle d'apprentissage, ce qui favorise le sur-apprentissage ou sur-ajustement (overfitting).
- ❖ **Les réseaux de neurones convolutionnels (CNN)** : Le problème est divisé en sous parties, et pour chaque partie, une grappe (cluster) de neurones sera créée afin d'étudier cette portion spécifique. Par exemple, pour une image en couleur, il est possible de diviser l'image sur la largeur, la hauteur et la profondeur (les couleurs).
- ❖ **Les réseaux de neurones à mémoire court-terme et long terme (LSTM)** : Ces réseaux sont utilisés sur des données triées temporellement. Dans certains cas d'usage, il est important de savoir quelles décisions ont été prises dans le passé afin de prendre une décision optimale à l'instant t.
- ❖ **La machine de Boltzmann profonde (Deep Belief Network)** : Ces algorithmes fonctionnent suivant une première phase non supervisée, suivie de l'entraînement classique supervisé. Cette étape d'apprentissage non-supervisée permet, en outre, de faciliter l'apprentissage supervisé.

Notre objectif est la recherche d'un modèle prédictif «interprétable» capable de décrire et de prédire en même temps. Dans cette thèse, on s'intéresse exclusivement aux réseaux de neurones convolutionnels (CNN) et aux réseaux de neurones à mémoire court et long terme (LSTM).

5.2 Les réseaux de neurones convolutionnels (CNN)

5.2.1 Le fonctionnement des réseaux de neurones convolutifs

Les réseaux de neurones convolutionnels sont à ce jour les modèles les plus performants pour les problèmes de classification. Ces réseaux sont capables de traiter et de catégoriser les signaux et les images. La couche d'entrée recevra les valeurs numériques correspondantes à l'attribut. S'il s'agit d'une image, l'entrée est fournie sous forme d'une matrice de pixels. S'il s'agit d'un signal, l'entrée est fournie sous forme d'un vecteur. Le CNN comporte deux parties bien distinctes. La première partie correspond aux couches de convolution, elle fonctionne comme un extracteur de caractéristiques. L'entrée passe à travers une succession de filtres, ou noyaux de convolution, créant de nouvelles matrices appelées cartes de convolutions. Certains filtres intermédiaires réduisent la résolution de l'entrée par une opération de maximum local. Ces techniques d'apprentissage supervisé peuvent fournir de très bons résultats et leurs performances dépendent fortement de la qualité des caractéristiques préalablement trouvées. Au final, les cartes de convolutions sont mises à plat et rassemblées en un vecteur de caractéristiques, appelé bloc CNN (Lepetit Aimon, 2018). Ce bloc CNN en sortie est ensuite branché en entrée d'une deuxième partie, constituée de couches entièrement connectées (perceptron multicouche, Figure 3.25). Les valeurs du vecteur subiront plusieurs transformations sous forme de combinaisons linéaires et par des fonctions d'activation pour renvoyer un nouveau vecteur en sortie, ce dernier vecteur contient autant d'éléments. Le rôle de cette partie est de combiner les caractéristiques du bloc CNN. La sortie est calculée par la

dernière couche de ce bloc (et donc du réseau) qui utilise une fonction logistique (classification binaire), une fonction *Softmax* (classification multi-classe) ou une fonction *Purlin* (problème de régression) comme fonction d'activation.

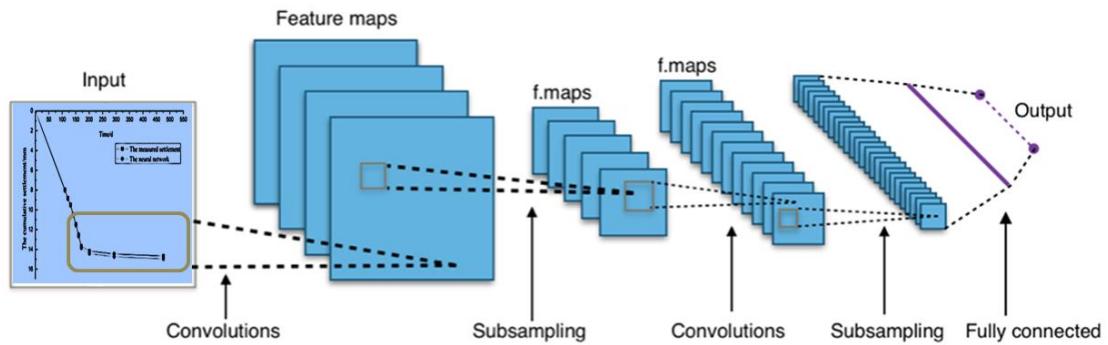


Figure 3.25 Structure typique d'un réseau neuronal convolutif.

5.2.2 Architecture de réseau de neurone convolutif

Un réseau neuronal convolutionnel se compose de plusieurs couches capables de capturer les dépendances spatiales et temporelles d'une image ou d'un signal grâce à l'application de filtres appropriés. Ce type de structure facilitera également la tâche du traitement par la réduction de la taille des images ou des signaux, sans perdre les fonctionnalités qui sont essentielles pour obtenir une bonne prédiction. Ceci est important lorsqu'il s'agira de concevoir une architecture qui est non seulement bonne pour l'apprentissage des fonctionnalités, mais qui est également évolutive pour des ensembles de données massifs.

5.2.2.1 Couche de convolution (CONV)

Les couches convolutives constituent le noyau du réseau convolutif. Elles passent les images d'entrée par un ensemble de filtres convolutifs, chacun de ces filtres active certaines caractéristiques des images (Figure 3.26). La première couche extrait les caractéristiques pertinentes de bas niveau telle que la couleur, l'orientation du dégradé et les bords de l'image. Les couches restant complètent les fonctionnalités de haut niveau.




Figure 3.26 L'opération de convolution sur la hauteur et la largeur d'une image.

5.2.2.2 Couche de pooling (POOL)

Pour rendre le processus d'apprentissage efficace, la couche de pooling extrait les caractéristiques dominantes qui sont invariantes en déplacement et en rotation. L'opération

simplifie la sortie en effectuant un sous-échantillonnage non linéaire (Figure 3.27) réduisant ainsi le nombre de paramètres que le réseau doit apprendre.

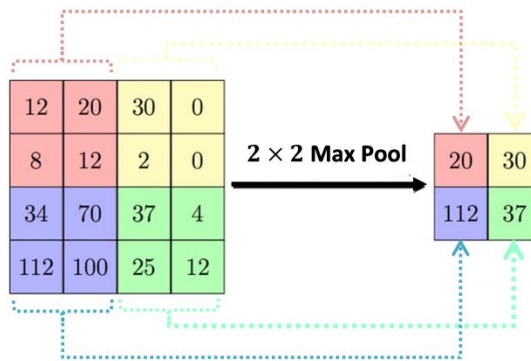


Figure 3.27 L'opération dans la couche max-pooling.

5.2.2.3 Couche entièrement connectée (FC)

L'apprentissage des combinaisons non-linéaires des caractéristiques de haut niveau représentées par la sortie de la couche de convolution et de pooling est traité via des couches totalement connectées. Cette couche est capable de faire une prédiction ultra-spécifique en combinant toutes les caractéristiques spécifiques détectées par les couches précédentes dans les données d'entrée.

5.3 Réseau de neurones à mémoire court- long terme (LSTM) :

La méthode « Long Short Term Memory –LSTM » est une méthode d'apprentissage automatique par réseaux de neurones qui tente de modéliser avec un haut niveau d'abstraction des données grâce à des architectures articulées de différentes transformations non linéaires. Sa puissance réside dans sa capacité à conserver plusieurs séquences d'informations dans la phase d'apprentissage. Ces techniques ont permis des progrès importants dans les domaines de l'analyse du signal sonore ou visuel, de la vision par ordinateur, du traitement automatisé du langage, etc.

5.3.1 Fonctionnement des réseaux de neurones LSTM

La topologie du réseau de neurone « Long Short Term Memory (LSTM) » est plus complexe que celle du réseau neurone ordinaire, en raison de leur fonctionnalité qui combine la gestion du block avec la mémoire (Figure 3.28).

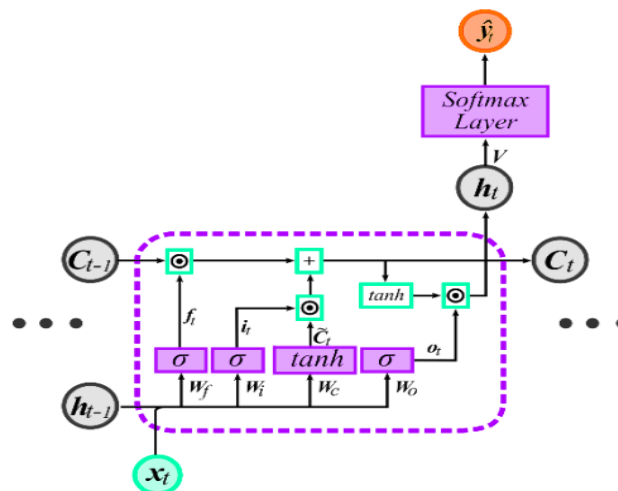


Figure 3.28 Bloc du réseau de neurone Long Short Term Memory (LSTM).

Un bloc LSTM comporte trois portes, une porte d'oubli qui va se charger de filtrer les informations contenues dans la cellule de la mémoire précédente (h_{t-1}), une porte d'entrée qui décide quelles nouvelles informations vont être autorisées à être stockées dans la cellule mémoire (C) et une porte de sortie qui fournira une décision h_t pour le bloc LSTM suivant. Les équations de 9 à 12 décrivent les opérations internes effectuées dans une unité neurale LSTM.

$$f_t = (w_f \times [h_{t-1}, x_t] + b_f) \quad (3.5)$$

$$i_t = (w_i \times [h_{t-1}, x_t] + b_i) \quad (3.6)$$

$$o_t = (w_o \times [h_{t-1}, x_t] + b_o) \quad (3.7)$$

$$C_t = (f_t \times c_{t-1} + i_t \times \tilde{C}_t) \quad (3.8)$$

Avec,

$$C_t = \tanh(W_C \times [h_{t-1}, x_t] + b_C) \quad (3.9)$$

$$h_t = o_t \times \tanh(C_t) \quad (3.10)$$

W_f, W_i, W_o, W_C sont des matrices de poids synaptiques et b_f, b_i, b_o, b_C sont les vecteurs biais correspondants.

6 Indicateurs de l'analyse techniques

Les différentes approches de calcul utilisées par les géotechniciens pour mesurer le tassement ont montré des signes de faiblesse avec une amplitude qui varie de 0.65 % à 1.5 %. Ces faiblesses ont conduit les chercheurs à tenter de trouver des alternatives pour réduire le degré d'incertitude. Plusieurs chercheurs ont préféré retourner vers le comportement réel du sol par le suivi des tassements et des durées d'acquisition (Asaoka, 1978; Gestin et Puiatti, 1980; Gioda et Sakurai, 1987; Baguelin, 1999; Mesri et Huvaj Sarihan, 2009). Cependant, l'utilisation des mesures seules dans les modèles de régression et les modèles intelligents reste moins informatif à cause des difficultés liées à la mauvaise caractérisation du comportement. Shahin (2008) affirme que l'utilisation de plusieurs paramètres d'entrée pour les modèles de régression et les modèles de l'intelligence artificielle permettent de mieux comprendre le phénomène d'aujourd'hui et mieux prévoir celui de demain. Cette technique est désormais accessible pour l'application en géotechnique afin de mieux comprendre le phénomène du tassement et les processus d'évolution. Les indicateurs techniques utilisés dans cette thèse permettent de caractériser totalement les mouvements complexes. Ces indicateurs doivent renfermer des informations relatives à l'accélération, à la vitesse, au changement de la direction et au sens principale du mouvement. Nous examinons par la suite les principales catégories d'indicateurs et nous fournissons un bref aperçu sur les fonctionnalités.

6.1 Rôle des indicateurs technique dans les études géotechniques

L'indicateur technique est une transformation mathématique qui vise à prévoir les futurs changements. Ceci constitue une opportunité d'identifier les différentes caractéristiques et les modèles de la dynamique qui sont invisibles. En conformité avec les propriétés fonctionnelles, les indicateurs peuvent être divisés en deux types, les indicateurs de tendance et les oscillateurs. Les indicateurs de tendance aident à identifier la direction et à trouver des moments d'inversion de tendance ou de retard. Les oscillateurs permettent de définir des points de retournement à l'avance ou simultanément. Ses propriétés sont très utiles pour analyser et caractériser correctement les

courbes du tassement et l'évolution de la pression interstitielle. Le fait d'ajouter d'autres paramètres d'entrée (Des indicateurs techniques) aux modèles développés augmente l'information qui améliore forcément la performance du modèle. Elle pourrait aussi réduire la probabilité d'être au minima local.

6.2 Indicateurs techniques de direction

6.2.1 Moyenne mobile (SMA)

La moyenne mobile, ou moyenne glissante est un type de moyenne statistique utilisée pour analyser et supprimer les fluctuations transitoires de façon à en souligner les tendances à long terme. Cette moyenne est dite mobile parce qu'elle est recalculée de façon continue, en utilisant à chaque calcul un sous-ensemble d'éléments dans lequel un nouvel élément remplace le plus ancien. Sur la figure 3.29, la courbe en rose est la moyenne mobile arithmétique (SMA) d'un cours d'action boursière calculée sur 20 jours (SMA20). Elle se calcule en additionnant le cours des 20 derniers jours et en divisant le résultat par 20.



Figure 3.29 Moyenne mobile arithmétique des cours de clôture (Williams, 1998).

6.2.2 Indicateurs technique d'oscillations

6.2.2.1 Indicateur Awesome Oscillator (AO)

L'oscillateur génial (AO) est un indicateur de type histogramme conçu pour mesurer la dynamique du mouvement. Il a été introduit par Bill Williams (1998). Le but de cet indicateur est de montrer ce qui se passe dans l'évolution récente. Il est utilisé pour confirmer les tendances et déterminer les points de renversement possible. La formule de calcul est relativement simple puisqu'il s'agit de soustraire une moyenne mobile de période 34 à une moyenne mobile de période 5. L'idée est donc de comparer deux moyennes mobiles d'horizons de temps différents, une de très court terme et une de moyen terme (équation 3.11).

$$AO = \text{Moyenne mobile (5)} - \text{Moyenne mobile (34)} \quad (3.11)$$

6.2.2.2 Momentum

Le Momentum (M) est l'un des indicateurs les plus connus de l'analyse technique, il fait partie de la famille des oscillateurs. Son objectif est de donner une mesure de la vitesse d'évolution à un moment donné. Cet indicateur évolue autour de la ligne du zéro, il est positif quand le mouvement est en accélération haussière et devient négatif dans la situation inverse (Figure 3.30). En effet, le calcul de Momentum au temps t est calculé comme suit :

$$M(t) = \text{cours}(t) - \text{cours}(t - x) \quad (3.12)$$

Où x est les jours qui ont précédé le jour t.



Figure 3.30 Calcul de la vitesse d'évolution par l'indicateur Momentum (Williams 1998).

6.2.2.3 Taux de variation (ROC)

Le taux de variation (ROC) est un indicateur de la famille des oscillateurs. Son principe est le même que celle du Momentum, il compare le mouvement du jour avec le mouvement des jours précédents. Sa lecture facile et rapide en fait un excellent indicateur sur les situations de tension. Le ROC est calculé par la formule suivante (équation 3.13) :

$$M(i) = \frac{\text{cours}(i) \times 100}{\text{cours}(i - n)} \tag{3.13}$$

Où Cours(i) est le cours à la date i et n la période.

6.2.2.4 Accélération et décélération (AC)

Dans une oscillation et juste avant de changer de direction, l'accélération de la force motrice se met à diminuer lentement jusqu'à atteindre le zéro. Ensuite, elle commence son accélération dans la direction opposée. L'indicateur AC dont on parle ici mesure l'accélération et la décélération de cette force. Cet indicateur est calculé en utilisant la formule suivante (équation 3.14) :

$$AC = AO - \text{Moyenne mobile}(AO, 5) \tag{3.14}$$

Où l'AO est Awesome Oscillator qui est utilisé pour mesurer la dynamique du marché et aide à déterminer la force de la tendance, y compris les points de sa formation et de son renversement, calculé à deux périodes, 5 et 34.

7 Conclusion

Ce chapitre décrit les approches basées sur l'intelligence artificielle. Ces dernières se composent en trois classes principales.

En premier lieu, ce sont les réseaux de neurones qui ont été abordés. La description des différents types existants et leurs domaines d'application a permis de discuter l'intérêt qu'ils peuvent présenter dans le domaine de la géotechnique.

Les méta-heuristiques ont fait l'objet d'une analyse critique dans le deuxième volet. Les méta-heuristiques à solution unique qui reposent sur une certaine intensification de l'espace de recherche comme la méthode de descente, le recuit simulé et la recherche tabou ont été décrites. Elles ont été

comparées aux méta-heuristiques à population de solutions qui implique une certaine diversification de l'espace de recherche, en particulier les algorithmes génétiques, les algorithmes de colonie de fourmis et la programmation génétique.

Enfin, ce sont les réseaux de neurones profonds tels que le réseau neuronal convolutif et le réseau récurrent qui ont été exposés.

Ces techniques d'apprentissage supervisé peuvent fournir de très bons résultats, et leurs performances dépendent fortement de la qualité des fonctionnalités (features) préalablement trouvées et l'interprétation des informations reçues par les différentes couches successives. Toutefois, le concept d'hybridation des méta-heuristiques est devenu un véritable challenge dans le domaine de l'optimisation, toutes les méta-heuristiques abordées précédemment peuvent être combinées de différentes manières afin d'aboutir à de nouveaux algorithmes d'optimisation.

Une présentation générale des indicateurs techniques a été effectuée à la fin. Elle sera exploitée pour une meilleure compréhension et caractérisation du phénomène de fluage dans le chapitre 5 de cette thèse.

Ce chapitre a été très utile à ce travail et notamment lors du développement des modèles basés sur les approches mentionnées ci-dessus.

CHAPITRE 4

LA PREDICTION DES PROPRIETES GEOTECHNIQUES DES SOLS

1 Introduction

Pour déterminer les paramètres des sols, l'Eurocode 7 (EN-1997-1) préconise de recourir aux essais et aux corrélations. Dans la pratique, les corrélations entre les paramètres sont employées comme un moyen de vérification des résultats d'essais sur le terrain et au laboratoire, et de générer des valeurs complémentaires de certains paramètres en fonction d'autres. En géotechnique, les corrélations sont surtout utilisées pour estimer certains paramètres des sols difficilement mesurables (généralement des paramètres mécaniques) en fonction d'autres paramètres facilement mesurables (généralement des paramètres physiques). Les relations établies entre les paramètres des sols s'effectuent au moyen des outils classiques de la statistique pour l'analyse des données. Dans ce cadre, la régression simple, la régression multiple et l'analyse factorielle ont fait l'objet d'une large utilisation (Djedid et al., 2001, Güllü et al., 2016). Ces méthodes présentent l'avantage d'être simples dans l'utilisation. Néanmoins, elles donnent souvent des coefficients de corrélations très faibles, notamment si des discontinuités sont présentes dans la distribution des mesures comme la présence de plusieurs sous-nuages nettement dissociés. Dans ce contexte-là, la recherche de modèles assez puissants qui répondent aux besoins des ingénieurs avec une représentativité acceptable est devenue nécessaire. Le présent chapitre vise l'application et la mise en œuvre des approches de l'intelligence artificielle (chapitre 3) pour estimer les paramètres du sol.

2 Estimation des paramètres de compressibilité

La durée importante des essais œdométriques conduit à utiliser, chaque fois que c'est possible, des corrélations avec des paramètres de détermination plus rapide, comme la teneur en eau, l'indice de vide et les limites d'Atterberg pour compléter la caractérisation des sols compressibles. Cette section se veut comme une contribution dans ce sens. Après avoir effectué une synthèse des travaux publiés depuis plus d'une trentaine d'année à propos des corrélations, nous avons proposé quatre approches basées sur les réseaux neurones artificiel (RNA), sur les réseaux neurones hybridés avec les algorithmes génétiques (NG), sur les réseaux neurones hybridés avec les essais particuliers (NN-PSO) et sur la programmation génétique mutigène (MGGP). Ces approches seront explorées pour une bonne prédiction de deux paramètres qui sont l'indice de compression (C_c) et l'indice de compression secondaire (C_α), paramètres caractérisant les sols compressibles.

2.1 Prédiction de l'indice de compression C_c

2.1.1 Description et traitement de la base de données

Dans cette étude, nous avons utilisé une base de données de 391 mesures réalisées par Kalantary et Kordnaej (2012) sur des échantillons de différente nature, des argiles limoneuses à haute plasticité (CH), des argiles sableuses à faible plasticité (CL), des limons sableux à haute plasticité (MH), des sables argileux fins (ML) et des limons à faible plasticité (CL-ML). Le tableau 4.1 récapitule les plages de variation des paramètres et leurs valeurs moyennes.

Tableau 4.1 Variation et valeurs moyennes des propriétés des sols étudiés.

Paramètres	Intervalles des valeurs	Moyennes
LL	[24.00-81.00]	39.84
LP	[3.00-50.00]	18.69
W_n	[10.20-70.00]	28.67
e_0	[0.36-1.88]	0.769
G_s	[2.43-2.80]	2.636
C_c	[0.05-0.63]	0.205

La base de données a été divisée en trois parties, 330 données pour l'apprentissage, 10 données pour les tests et 51 données pour la validation (51). Les données d'apprentissage sont utilisées pour entraîner les modèles prédictifs, les données de validation sont utilisées pour arrêter le processus d'apprentissage et les données des tests sont utilisées pour évaluer les modèles. Après le partage, les données ont été transformées par un logarithme de base 10 afin d'obtenir des données réparties de façon normale. Notre choix était fondé sur le fait que nos données ont une distribution asymétrique. Les paramètres d'entrée utilisés pour les modèles sont l'indice de vides initial (e_0), la teneur en eau naturelle (w_n), la densité des gains solide (G_s), la limite de liquidité (LL) et la limite de plasticité (LP). La méthodologie utilisée comprend d'abord l'utilisation d'une analyse de régression simple pour mettre en évidence l'existence des relations linéaires ou non linéaires significatives entre les paramètres d'entrée et le paramètre de sortie C_c .

2.1.2 Régression simple

Une analyse par régression simple a été effectuée pour juger la qualité de la régression et l'adéquation entre le modèle et les données observées. Ceci aide à choisir les variables d'entrée du modèle en question et permet aussi de se prononcer dans quelle mesure l'équation de régression décrit-elle la distribution des points. Cette étape vise à réduire le risque d'être au minimum local.

Les résultats sont présentés sur les figures 4.1, 4.2, 4.3, 4.4 et 4.5 qui correspondent respectivement aux paramètres (e_0 , w_n , G_s , LL , LP). La corrélation est représentative pour les paramètres physiques à savoir, l'indice des vides initial (e_0) et la teneur en eau naturelle (w_n). Pour la densité des grains solides (G_s), la limite de liquidité (LL) et la limite de plasticité (LP), le coefficient de corrélation R^2 est inférieur à 0,15. Ceci signifie que les modèles mathématiques utilisés ne peuvent être représentatives pour expliquer la distribution des points. Il est parfois difficile de trouver un modèle à la fois performant (résidus les plus petits possibles) et économique (le moins possible de variables explicatives). Pour cette raison, le choix des variables entrant dans un modèle s'effectue généralement pas à pas, en commençant par la recherche et la sélection des variables qui expliquent le mieux la variable cible, puis on intègre par la suite les variables à faible corrélation, mais leurs interactions avec celle qui a été sélectionnée précédemment permet de contrôler statistiquement le modèle. Dans cette étude, tous les paramètres faiblement corrélés ont un degré d'association assez élevé avec les variables dépendantes. Ça veut dire que ces paramètres n'ayant pas un lien direct avec la variable cible mais une liaison assez forte avec les paramètres influents. C'est pour cette raison qu'on adopte les cinq variables cités plus haut.




Figure 4.1 Régression simple pour le paramètre e_0




Figure 4.2 Régression simple pour le paramètre w_n




Figure 4.3 Régression simple pour le paramètre G_s




Figure 4.4 Régression simple pour le paramètre LL




Figure 4.5 Régression simple pour le paramètre LP .

2.1.3 Prédiction de l'indice de compression par le RNA

2.1.3.1 Le paramétrage du RNA

Le programme réalisé à cet effet l'a été sous environnement Matlab. Le réseau choisi pour cette étude est un 'Feed-Forward' de type perceptron multicouches avec un algorithme d'optimisation rétro-propagation résilient 'trainrp'. Cet algorithme engendre un apprentissage plus rapide et une meilleure performance globale du réseau. L'une des principales différences entre la rétro-propagation standard et le 'trainrp' réside dans la méthode de calcul du gradient. La rétro-propagation standard impose un taux d'apprentissage constant pour tous les poids et les biais, tandis que 'Trainrp' a un taux d'apprentissage variable, il augmente lorsque le gradient ne change pas de signe (ce qui signifie qu'elle est dans la bonne direction) ou diminue lorsque le gradient change de signe. Nous avons utilisé la fonction «Sigmoid» comme une fonction d'activation dans les couches cachées et la fonction « Purelin » pour la couche de sortie. La détermination du nombre optimal des neurones dans les couches cachées est effectuée par la fixation de tous les autres paramètres (nombre de couches cachées, nature de la fonction d'activation, algorithme d'apprentissage) et de faire varier le nombre de neurones dans les couches cachées. Les performances ont été évaluées en fonction de l'erreur absolue moyenne (MAE) et le coefficient de corrélation (R).

2.1.3.2 Validation

Afin de mener cette recherche, les paramètres physiques du sol, qui sont e_0 , w_n , G_s , LL et LP ont été combinés et fournis au RNA pour obtenir à la fin cinq réseaux de neurone (RNA1, RNA2,

RNA3, RNA4 et RNA5). Ces valeurs spectrales sont données en \log_{10} et transformées par la puissance de dix. Les poids synaptiques qui offrent les meilleures performances sont stockés dans des matrices et des vecteurs nommés W_1 , W_2 , W_3 , B_1 et B_2 . Le tableau 4.2 présente les performances des modèles développés.

Tableau 4.2 Erreurs absolues moyennes du test pour les modèles RNA

Sortie	Algorithme	Modèle	Entrée	Architecture du réseau	Test	
					R	MAE
Cc	trainrp	RNA1	LL, PL	2-25-30-1	0,20	0,089
		RNA2	e_0, w_n	2-19-16-1	0,97	0,032
		RNA3	e_0, w_n, PL	3-38-06-1	0,98	0,038
		RNA4	e_0, w_n, PL, LL	4-21-48-1	0,98	0,024
		RNA5	e_0, w_n, PL, LL, G_s	5-31-37-1	0,63	0,027

La comparaison des performances du réseau développé dans cette étude avec la base de test est montrée sur les figures (4.6, 4.7, 4.8, 4.9 et 4.10).




Figure 4.6 Comparaison entre les valeurs mesurés et prédit par RNA1




Figure 4.7 Comparaison entre les valeurs mesurés et prédit par RNA2




Figure 4.8 Comparaison entre les valeurs mesurés et prédit par RNA3




Figure 4.9 Comparaison entre les valeurs mesurés et prédit par RNA4




Figure 4.10 Comparaison entre les valeurs mesurées et prédit par RNA5

Une nette amélioration de la qualité a été constatée avec l'utilisation des paramètres ayant une influence sur l'indice de compression. Par rapport au modèle RNA1, l'erreur absolue moyenne a été réduite de 64 % par le modèle RNA2. Malgré cette amélioration, l'erreur absolue moyenne reste toujours excessive et inadmissible. Le modèle RNA3 n'a pas réussi à prévoir la plupart des points. Au contraire, l'interaction de la limite de plasticité (LP) avec les paramètres (e_0 , w_n) a exercé une influence négative sur la performance du modèle. Cependant, dans le réseau RNA4, l'interaction entre les deux paramètres faiblement corrélés (LL , LP) et les paramètres fortement corrélés (e_0 , w_n), a apporté des résultats meilleurs. L'erreur absolue moyenne est réduite de 37% avec une hausse dans le temps de calcul. Le modèle RNA5 comporte plus de neurones et plus de liens synaptiques (5 neurones en entrée, 31 neurones pour la première couche caché, 37 neurones pour la deuxième et 1 neurone de sortie). Cela implique que l'accroissement de la complexité n'améliore pas nécessairement le taux de reconnaissance sur l'échantillon mais nécessite un algorithme d'apprentissage très puissant, capable d'appliquer un cheminement logique pour trouver un optimum global.

2.1.3.3 Problèmes rencontrés avec RNA

Plusieurs limites dans l'utilisation des réseaux de neurones peuvent être retenues. On précise qu'il n'existe pas encore de théorie permettant de déterminer la structure optimale d'un réseau. En particulier, la détermination du nombre de couches cachées et du nombre de neurones sur chacune d'entre elles relève encore largement de l'intuition de l'utilisateur et de sa capacité à expérimenter plusieurs architectures afin de retenir celle qui donne les meilleurs résultats. Bien que l'algorithme d'apprentissage de rétro-propagation par gradient ait obtenu un succès évident, dans certaines situations, l'algorithme ne peut pas garantir une convergence universelle. La plupart des dysfonctionnements sont dus au long processus d'apprentissage. Cela peut être dû à une sélection incorrecte du taux d'apprentissage γ , du moment α , des valeurs des poids initiaux, de l'apprentissage par succession. Plusieurs algorithmes avancés peuvent être utilisés pour remplacer la rétro-propagation du gradient. Notre choix s'est porté sur l'algorithme génétique pour la suite de cette étude. Cet algorithme itératif permet d'orienter correctement et efficacement la direction de recherche vers une solution optimale.

2.1.4 Prédiction de l'indice de compression par le NG

L'apprentissage des poids d'un réseau de neurones est généralement obtenu en minimisant une fonction d'erreur. Cette fonction d'erreur est calculée à l'aide d'un groupe d'éléments d'apprentissage, pour lesquels les entrées ainsi que les sorties espérées sont connues. La plupart des

méthodes d'apprentissage, telle que la méthode de rétro-propagation du gradient ou les algorithmes de gradients conjugués, sont basées sur la descente du gradient. Ces méthodes ont obtenu de grands succès dans de nombreuses applications. Cependant, un des problèmes fréquemment rencontré lors de l'apprentissage de réseaux de neurones complexes, est la convergence vers des optima locaux. A 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'éviter cette convergence inappropriée, les chercheurs ont proposé une approche un peu plus élaborée, l'apprentissage hybride. Cette approche consiste à combiner les AG et les RNA, pour bénéficier des avantages combinés de chacune des deux méthodes.

2.1.4.1 Paramétrage du NG

Plusieurs paramètres peuvent donner des résultats satisfaisants, il n'y a pas unicité de paramétrage face à un problème donné. Afin d'éviter la perte d'informations, il est généralement recommandé de définir un taux d'élite différent à zéro. En fait, en l'absence d'élitisme, la meilleure solution trouvée dans la génération n'est pas forcément transmise à la génération suivante, ce qui peut entraîner une perte d'informations. Pour une raison de comparaison, nous avons gardé la même topologie (nombre de couches cachées, le nombre de neurone dans les couches cachés et la nature de la fonction d'activation) que celle des réseaux développés (RNA1, RNA2, RNA3, RNA4 et RNA5). Les opérateurs de l'algorithme génétique sont guidés par un certain nombre de paramètres fixés à l'avance, comme le montre le tableau 4.3 ci-après.

Tableau 4.3 Paramètres du modèles NG

Catégories	Variables	Valeurs
Population	Taille de la population	100
Critère d'arrêt	Nombre de générations	100
Sélection	Taux d'élites	0,05
	Pas de sélection	0,9
Croisement	Probabilité de croisement	0,9
Mutation	Probabilité de mutation	0,01

2.1.4.2 Validation

Le tableau 4.4 indique les différents modèles de prévision obtenus par le modèle neuro-génétique.

Tableau 4.4 Les erreurs absolues moyennes du test pour les modèles NG.

Sortie	Algorithme	Modèle	Entrée	Architecture du réseau	MAE	
					R	Test
Cc	AG	NG1	LL, PL	2-25-30-1	0,31	0.0889
		NG2	e_0, w_n	2-19-16-1	0,96	0.0293
		NG3	e_0, w_n, PL	3-38-06-1	0,99	0.0228
		NG4	e_0, w_n, PL, LL	4-21-48-1	0,99	0.0219
		NG5	LL, PL, w_n, e_0, G_s	5-31-37-1	0,99	0.0175

Les performances ont été évaluées par l'erreur absolue moyenne (MAE), le meilleur modèle obtenu est celui qui possède le plus d'interconnexions (NG5). Cela montre que, malgré la présence d'un nombre important des poids synaptiques, l'algorithme génétique a réussi à produire de meilleures solutions.




Figure 4.11 Comparaison entre les valeurs mesurés et prédit par NG1




Figure 4.12 Comparaison entre les valeurs mesurés et prédit par NG2




Figure 4.13 Comparaison entre les valeurs mesurés et prédit par NG3




Figure 4.14 Comparaison entre les valeurs mesurés et prédit par NG4




Figure 4.15 Comparaison entre les valeurs mesurés et prédit par NG5

On remarque que les modèles NG2, NG3, NG4 et NG5 s'approchent d'une manière très satisfaisante des points mesurés, c'est-à-dire qu'ils assurent une bonne représentativité des données (Figures 4.12, 4.13, 4.14 et 4.15). Par contre, le modèle NG1 qui comporte 25 neurones dans la première couche caché et 30 neurones dans la deuxième, assure une mauvaise représentativité des données (Figure 4.11). Cela est dû probablement à l'utilisation de paramètres qui ne sont pas liés à l'indice de compression. On peut également noter que l'erreur absolue moyenne diminue avec l'accroissement du nombre de variables d'entrée. Ces variables ont conduit à une réduction

considérable (environ de 50%) lors du passage de 2 variables à 5 variables (Figures 4.12 et 4.15). En effet, des études similaires (Tang et al 1991) ont montrées que, plus on augmente le nombre des entrées plus le modèle réussi à reproduire de meilleures performances.

2.1.4.3 Comparaison entre RNA et NG

Tous les résultats obtenus sont présentés graphiquement pour des comparaisons. Cette présentation permet de tester la robustesse des modèles proposés dans la prédiction et la fiabilité dans la recherche d'une solution optimale. Les variations de l'indice de compression généré par les cinq modèles sont représentées respectivement sur les figures 4.16, 4.17, 4.18, 4.19 et 4.20. L'étude montre que l'analyse par neuro-génétique donne des résultats plus précis pour la prédiction de l'indice de compression. L'apprentissage à l'aide des algorithmes génétiques a donné une erreur moyenne deux fois inférieure à celle du réseau neurone. Ceci ouvre une voie intéressante pour atteindre le niveau requis de robustesse pour des développements futurs. Il faut noter qu'il existe d'autres meilleures topologies, qui permettent d'obtenir d'excellentes performances en termes de précision et temps de calcul. Ces topologies n'ont pas été données pour des raisons de comparaison, le processus d'optimisation ne porte que sur les poids du réseau de neurones. L'architecture du réseau est fixée au départ, le nombre de neurones ainsi que leurs connexions restent donc inchangées au cours de l'apprentissage.




Figure 4.16 Comparaison entre le modèle RNA1 et NG1




Figure 4.17 Comparaison entre le modèle RNA2 et NG2




Figure 4.18 Comparaison entre le modèle RNA3 et NG3




Figure 4.19 Comparaison entre le modèle RNA4 et NG4




Figure 4.20 Comparaison entre le modèle RNA5 et NG5

Pour tester la validité des résultats obtenus, une comparaison avec d'autres travaux dans le même domaine a été effectuée, elle est donnée par le tableau 4.5. Les performances des modèles NG et les modèles RNA sont évaluées simultanément par les paramètres MAE et le coefficient de corrélation.

L'étude a montré que les modèles à deux variables (Tableau 4.5) n'ont pas réussi à prédire correctement l'indice de compression C_c . Cela peut être dû à une absence ou à des contradictions dans les informations recueillies, ce qui empêche d'établir une relation de dépendance entre l'indice de compression et les propriétés physiques du sol. L'analyse par NG a fourni des résultats plus précis pour la prédiction de l'indice de compression. Cependant, des améliorations peuvent être apportées pour garantir une meilleure prédiction, comme par exemple augmenter le nombre de neurone dans les couches cachées. Contrairement aux modèles RNA, l'augmentation du nombre de variables à l'entrée des modèles NG (NG3, NG4 et NG5) améliore significativement leurs performances (Tableau 4.5). À partir des résultats obtenus, nous pouvons dire que la combinaison de l'algorithme génétique et du réseau de neurone a permis d'avoir un système qui combine l'efficacité des AG dans la recherche des solutions globales et la capacité des RNA à reproduire des relations complexes non linéaires.

2.1.4.4 Problèmes rencontrés avec NG

Les algorithmes génétiques sont particulièrement utiles dans le cas d'espaces de très grande taille et qui présentent des optima locaux difficiles à explorer avec des algorithmes déterministes. Ils constituent un bon moyen pour éviter les optima locaux et pour fournir l'optimum global du problème quelle que soit la solution initiale choisie. Cependant, un des problèmes principaux des AG est leur lenteur dans la convergence. Le second inconvénient est que leurs résultats dépendent fortement du choix des paramètres associés. Pour remédier au premier inconvénient, c'est-à-dire la convergence, une approche un peu plus élaborée a été proposée, l'apprentissage par les essais particuliers. Cette approche se caractérise par une mise en œuvre facile et une convergence rapide.

2.2 Prédiction de l'indice de compression secondaire C_α

Les sols fins argileux ont la particularité de produire un tassement qui peut être divisé en deux phases, un tassement primaire et un tassement secondaire. Le premier est plus ou moins rapide et est dû à l'expulsion de l'eau contenu dans les vides du sol. Le second est beaucoup plus lent, il est dû à la déformation des particules solides et met plusieurs années pour se stabiliser. Ce phénomène, dit fluage, est difficile à étudier car il soulève de nombreuses difficultés liées principalement à la complexité de la structure des sols fins et à leurs comportements. Le paramètre le plus couramment utilisé pour caractériser ce fluage est le coefficient de compression secondaire, noté souvent C_α . Cet

indice, qui est un paramètre clé pour la plupart des modèles de comportement viscoplastique applicables dans la pratique (Yin et al., 2017a, Yin et Karstunen, 2011; Yin et Graham, 1989), est généralement obtenu par des essais œdométriques conventionnels. Dans cette étude, deux nouvelles approches sont proposées pour prédire ce paramètre, l'une basée sur une hybridation entre les réseaux de neurones artificiels et les algorithmes d'optimisation par essais particuliers et l'autre sur une programmation génétique multi-gènes.

Tableau 4.5 Performances des modèles empiriques et développés.

Auteurs	Entrées	R	MAE
Khafaji et Andersland (1992)	LL, e_0	0,97	0,280
Ahadiyan et al. (2008)	LL, e_0	0,97	0,043
Koppula (1981)	LL, w_n	0,88	0,241
Azzouz et al. (1976)	LL, w_n	0,94	0,047
Park et Lee (2011)	LL, G_s	0,42	0,127
Nagaraj et Murthy (1985)	LL, G_s	0,42	0,098
RNA1	LL, PL	0,20	0,089
NG1	LL, PL	0,31	0,089
Rendon Herrero (1983)	G_s , e_0	0,97	0,036
RNA2	e_0 , w_n	0,97	0,033
NG2	e_0 , w_n	0,96	0,029
Yoon et Kim (2006)	LL, e_0 , w_n	0,94	0,083
Azzouz et al. (1976)	e_0 , w_n , LL	0,98	0,029
Azzouz et al. (1976)	e_0 , w_n , LL	0,97	0,027
RNA3	e_0 , w_n , PL	0,98	0,038
NG3	e_0 , w_n , PL	0,99	0,0228
RNA4	e_0 , w_n , PL, LL	0,98	0,024
NG4	e_0 , w_n , PL, LL	0,99	0,0219
RNA5	e_0 , w_n , PL, LL, G_s	0,63	0,0265
NG5	e_0 , w_n , PL, LL, G_s	0,99	0,0175

2.2.1 Description et traitement de la base de données

La base de données représente l'environnement d'apprentissage pour les deux algorithmes proposés (MGGP et NN-PSO). Dans cette étude, nous avons utilisé 203 mesures provenant de différents sites (Figure 4.21).

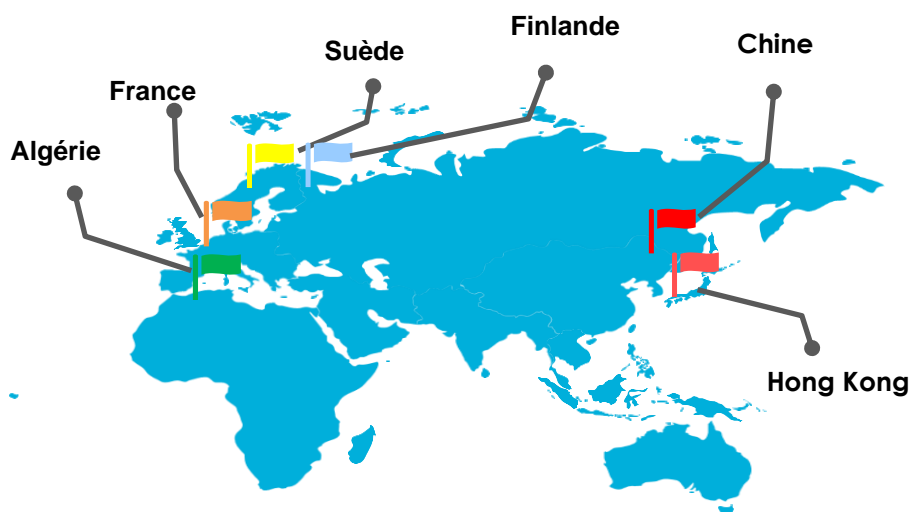


Figure 4.21 Localisation des zones d'échantillonnage

La base de données a été divisée en deux parties : une première partie pour l'apprentissage (193) et une deuxième partie pour le test (10). Les données d'apprentissage ont été utilisées pour former les modèles et les données du test ont été utilisées pour évaluer leurs performances. Les variables d'entrée utilisées sont la teneur en eau naturelle (w_n) exprimé en pourcentage, l'indice de vide initial (e_0) et la contrainte verticale (σ_v) exprimée en kilo-pascal. Le tableau 4.6 ci-dessous résume les plages de variation et les valeurs moyennes des paramètres utilisés.

Tableau 4.6 Les plages de variation des paramètres

Type	Symbol	Intervalle
Entrées	w_n	[10-93]
	e_0	[0.6-1.08]
	σ_v	[10-5000]
Sortie	C_α	$[0.43 \times 10^{-3} - 3.5 \times 10^{-3}]$

2.2.2 Régression simple

Une analyse de régression simple a été effectuée sur les données recueillies afin d'identifier les paramètres d'entrée utiles. Les résultats de cette analyse sont présentés sur les figures 4.22, 4.23 et 4.24 pour les trois paramètres, teneur en eau naturelle (w_n), indice des vides initial (e_0) et la contrainte verticale (σ_v). Les graphiques (Figures 4.23 et 4.24) montrent clairement une absence de relation de l'indice C_α avec la teneur en eau naturelle et une faible relation avec les paramètres (e_0) et (σ_v).




Figure 4.22 Régression simple pour le paramètre w_n




Figure 4.23 Régression simple pour le paramètre e_0




Figure 4.24 Régression simple pour le paramètre σ_v

Les faibles coefficients de corrélation montrent qu'il n'y a pas de relation linéaire significative entre les variables testées deux à deux. Ceci ne veut pas dire qu'il n'existe pas de relation entre ces variables, des fonctions mathématiques non linéaires peuvent améliorer considérablement les prévisions des modèles de régression.

2.2.3 Prédiction de l'indice de compression par NN-PSO

Les premiers réseaux de neurones n'étaient pas capables de résoudre des problèmes non linéaires. Cette limitation fut dépassée par l'utilisation de la rétro-propagation du gradient de l'erreur dans les systèmes multicouches. Cette technique a pour but de faire converger rapidement le processus de manière itérative vers une configuration optimisée des poids synaptiques. Lors de l'application de cette procédure, des problèmes ont été rencontrés durant l'apprentissage par l'obtention de zones très plates et des minima locaux. Pour cette raison, l'hybridation du réseau neurones NNA et de l'optimisation par essaim particulaire PSO a été utilisée. En d'autres termes, au lieu d'effectuer l'apprentissage par l'algorithme de rétro-propagation du gradient, il sera réalisé par les mécanismes du PSO comme le montre la figure 4.25.




Figure 4.25 Identification du coefficient de consolidation secondaire.

Le traitement possède N entrées ($x_1, x_2, \dots, x_i, \dots, x_n$), plusieurs couches cachées et une couche de sortie calculée à partir d'une fonction de seuillage f , dite aussi la fonction d'activation, de la somme pondérée. Lorsque l'entrée est présentée aux neurones dans la couche cachée, la sortie est modifiée selon l'équation suivante :

$$S_i = f \left(\sum_{i=1}^n w_{ij} \times x_i + b_j \right) \tag{4.1}$$

w_{ji} indique la pondération de la connexion entre le neurone de la couche cachée et la $i^{ème}$ entrée, b_j est le biais associé à la $j^{ème}$ neurone et f est la fonction d'activation du neurone de cette couche. Le calcul d'une sortie pour un neurone qui se trouve dans une couche de sortie s'effectue comme suit :

$$S = g \left(\sum_{i=1}^m w_{kj} \times S_j \right) \tag{4.2}$$

w_{kj} est la pondération entre le neurone de la sortie et le $j^{ième}$ neurone de la couche cachée, m est le nombre de neurones de la couche cachée et g est la fonction d'activation du neurone de la couche cachée du réseau. L'algorithme doit fournir au réseau les meilleurs poids de connexion, il permet de modifier les paramètres du réseau afin d'avoir le comportement désiré. La modification des paramètres du réseau est articulée sur la minimisation de la fonction coût quadratique entre la sortie prédit et la sortie mesurée du réseau conformément à l'équation 4.3.

$$F_{min} = \left(\sum_{i=1}^n |y_{\text{Predicted}} - y_{\text{Measured}}| \right)^2 \quad (4.3)$$

2.2.3.1 Paramétrage du NN-PSO

La programmation et la validation des résultats du modèle ont été conduites par le logiciel Matlab. Le prétraitement des données a été effectué avec la fonction "Min-max" afin d'assurer une normalisation qui facilitera la présentation de la théorie des réseaux de neurones. Le programme commence par l'entraînement du réseau, c'est-à-dire qu'il calcule les poids synaptiques optimaux avec le PSO, puis il calcule la sortie du réseau pour chaque neurone. La taille de la population a été fixée à 200 particules. Ce paramètre a une influence sur le comportement de l'algorithme. En effet, une petite population ne crée pas assez d'interactions garantissant le bon fonctionnement de l'algorithme. Pour le coefficient d'accélération, s'il est trop petit, l'exploration par l'algorithme sera très lente, ce qui limite sa performance. Selon Kuok et al. (2010), une valeur de 2.05 donne de bons résultats. Pour le paramètre d'inertie qui gère l'influence de la direction du déplacement par rapport au déplacement futur, il est choisi selon une distribution uniforme proposée par Eberhart et Kennedy (1995) dans l'intervalle [0.5 - 1]. Dans notre cas, nous avons choisi la valeur de 0.5 que nous avons jugée convenable. Le PSO commence à chercher une solution appartenant à un espace de recherche X qui minimise ou maximise le critère particulier de la fonction fitness F_{min} (Equation 1.3). Ces valeurs sont ensuite injectées dans le réseau comme des poids synaptiques. Cette opération se répète tant que le critère de convergence n'est pas atteint. Les poids synaptiques seront modifiés de façon à minimiser la somme des écarts entre les résultats et les buts à atteindre. La configuration optimale du réseau est obtenue après plusieurs tests. Elle correspond à 8 neurones dans la première couche cachée, 10 neurones dans la deuxième couche cachée et un seul neurone dans la couche de sortie. Comme fonction d'activation, c'est la fonction tangente hyperbolique et la fonction linéaire saturée qui ont été utilisées pour les neurones des couches cachées. Pour la couche de sortie, c'est une fonction linéaire qui a été utilisée.

2.2.3.2 Validation

La comparaison entre les résultats obtenus par l'approche d'optimisation adoptée et les résultats expérimentaux montre une bonne concordance entre les simulations et les mesures. Ceci montre que l'algorithme d'optimisation NN-PSO est performant avec un taux d'erreur moyen de 9,6 % (Tableau 4.7).

Tableau 4.7 Comparaison entre les valeurs mesurées et prédites par NN-PSO

w_n	σ_v	e_0	Mesuré ($\times 10^{-3}$)	Prédit ($\times 10^{-3}$)	Erreur
66.8	22.29	1.000	1.67996	1.76148	0.08152
27.2	401.88	0.730	0.91599	0.80122	0.11477
70.5	10.92	1.040	1.97876	2.03187	0.05311
67.6	11.93	1.020	1.69676	1.84929	0.15253
27.3	206.43	0.755	0.83646	0.78890	0.04756
70	19.66	1.000	1.93996	2.02533	0.08537
27.7	1616.18	0.700	1.26872	1.17794	0.09079
61	22.79	0.950	1.63796	1.54331	0.09465
93.6	202.98	0.843	4.97607	4.83140	0.14467
79.9	27.56	0.990	2.92526	3.02732	0.10206
MAE					0.09670
R					0.999

La stratégie du prétraitement utilisée a joué un rôle important dans l'amélioration de la qualité des modèles prédictifs. Notre stratégie a comporté deux étapes fondamentales, la première a consisté en l'élimination des valeurs aberrantes qui se situent très loin des autres valeurs de l'ensemble des données (dans notre cas, les sols organiques) et la deuxième étape a consisté en la normalisation des données par une fonction Min-max qui conserve la distribution des valeurs originales à un facteur d'échelle près et transforme les valeurs dans l'intervalle $[0,1]$. Le traitement de la première phase a été effectué à partir de la primitive conditionnel «if» en utilisant la MGGP. Avec cette primitive, le système cherche le critère le plus déterminant et découpe la population en sous populations possédant la même entité de ce critère. Ce qui nous a facilité la définition du domaine d'application des deux modèles développés. La fonction d'activation d'une unité neuronale peut accepter des valeurs d'entrée de n'importe quel ordre de grandeur et produira des sorties dans un intervalle strictement limité. Pour une fonction sigmoïde, si les valeurs d'entrées sont situées en dehors de l'intervalle $[0, +1]$, le neurone perd l'information à cause d'une saturation. Cet effet va sévèrement limiter la possibilité du réseau à détecter la relation entrée-sortie. Cela signifie que l'ordre de positionnement de ses fonctions peut profondément influencer la performance du réseau de neurones. Les résultats de NN-PSO ont montré que nos choix de positionnement, de la fonction tangente hyperbolique dans la première couche cachée et de la fonction linéaire saturée dans la deuxième couche cachée, ont été judicieux et ont permis d'éviter ce phénomène.

2.2.3.3 Problèmes rencontrés avec NN-PSO

L'analyse par le NN-PSO manque de transparence, la sortie est obtenue sous forme de valeurs numériques. Aucune information ne peut être recueillie sur l'effet de chaque entrée sur la sortie, c'est un fonctionnement en «boîtes noires». L'obtention de solutions exactes pour tous les problèmes pratiques se révèle souvent hors de portée pour plusieurs raisons. En effet, la production d'une solution exacte d'un problème requiert généralement une formulation analytique du problème avec des conditions initiales et aux limites convenables, ce qui n'est souvent pas possible compte tenu des contraintes pratiques. Ajouté à cela, la variabilité multidimensionnelle des paramètres, la complexité des bases de données avec toutes les conséquences que cela implique (bruits, données aberrantes ou manquantes, haute dimensionnalité, etc.). Même lorsque le problème est entièrement défini et qu'un algorithme le résolvant est connu, d'autres difficultés surgissent comme la convergence du processus, la fiabilité du résultat, le temps de calcul, etc. D'autres problèmes peuvent aussi être rencontrés comme le cas où il n'y a pas un optimum global bien défini, tels les problèmes multi-objectifs où chaque solution constitue un compromis entre différents objectifs. Pour toutes ces raisons, nous nous sommes dirigés vers la méthode MGGP, une méthode qui nécessite généralement moins d'effort de calcul et garantit souvent une solution optimale. Bien que la MGGP a été toujours un sous-domaine en optimisation et en apprentissage automatique, ses caractéristiques particulières la distinguent de la plupart des autres méthodes méta-heuristiques et offre des possibilités d'application inédites. L'un des principaux avantages de la MGGP est la liberté d'évoluer dans de très grands espaces de recherche. Généralement, assez peu de contraintes sont imposées au mécanisme d'évolution afin de permettre l'obtention d'une solution novatrice, qui vraisemblablement n'aurait pas pu être « pensée » ou « déduite ».

2.2.4 Prédiction de l'indice de compression par MGGP

2.2.4.1 Paramétrage du MGGP

Comme tout algorithme évolutionnaire, un ensemble de paramètres doit être ajusté pour initialiser, exécuter et arrêter le processus de recherche de la solution optimale. La MGGP nécessite de

connaître d’autres paramètres pertinents comme les terminaux (T) et les fonctions mathématiques (F). Généralement, il n’y a pas de méthode exacte pour trouver un paramétrage optimal de l’algorithme, car ceci dépend étroitement de la nature du problème étudié (Javadi et al, 2006; Sadok et al, 2016). Dans notre cas, c’est l’approche essai-erreur qui a été utilisée, elle permet d’ajuster les paramètres en fonction du résultat obtenu à chaque fois. Dans le tableau 4.8 sont reportés les principaux paramètres fixés dans le programme.

Tableau 4.8 les paramètres du model MGGP

Paramètres	Valeurs
Runs	60
Populations	500
Génération	100
Tournoi	2
Profondeur maximale de l'arbre	6
Max gènes	8
Terminal (T)	(w_n, e_0, σ_v)
Probabilité de croisement	0.85
Taux de probabilité de reproduction	0.1
Taux de probabilité de mutation	0.05
Fonction (F)	(Multiply, plus, minus, plog, tan, tanh, sin, cos, exp, log, div)

2.2.4.2 Validation

Pour la modélisation de l’indice de compression C_α par apprentissage automatique selon la MGGP, l’apprentissage s’effectue sur la base des données de l’apprentissage décrite ci-dessus. La modélisation intègre l’indice des vides initial, la teneur en eau et la contrainte verticale. Il est à rappeler que la performance « fitness » de chaque modèle représente la somme des erreurs absolues, ceci explique pourquoi la fitness de terminaison de la recherche dans le paramétrage de départ est fonction de la propriété modélisée. Notons que dans cette partie, l’apprentissage automatique par la MGGP nécessite de paramétrer l’algorithme au préalable afin d’obtenir un résultat optimal, traduit par un modèle de grande précision dans la prédiction. Les résultats des prédictions sont comparés aux résultats expérimentaux. Les figures 4.26 et 4.27 représentent le meilleur modèle trouvé sous forme des arbres syntaxiques.

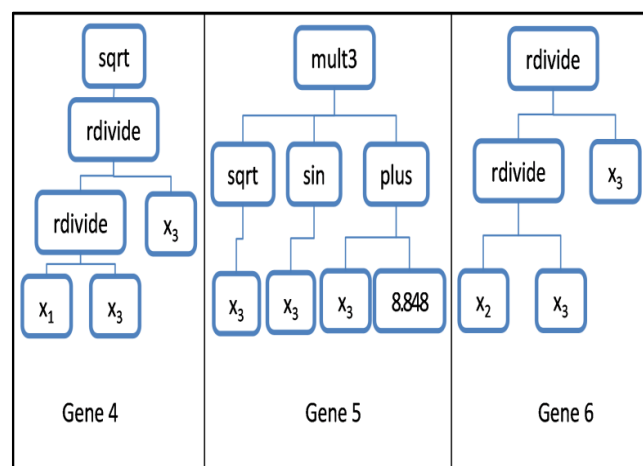
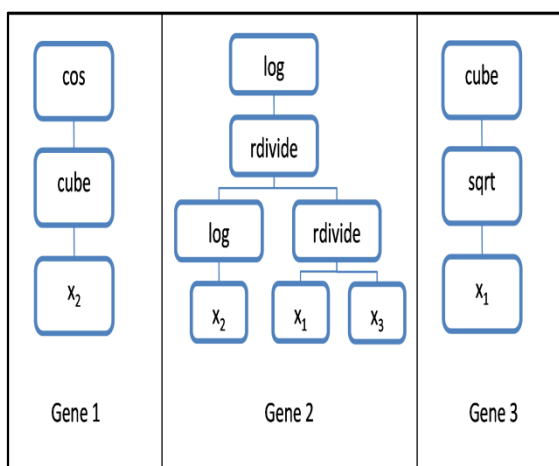


Figure 4.26 les arbres syntaxiques du gène 1, 2 et 3, Figure 4.27 les arbres syntaxiques du gène 4, 5 et 6

Le meilleur individu retenu présente un coefficient de corrélation R égal à 0.9983, un RMSE de

0.0459 et un MAE de 0.0337. Le modèle obtenu à l'issu de cette optimisation est présenté par l'équation 1.4 :

$$C\alpha = 0.04483 \times \cos(\sigma_v)^3 + 1.984 \times \ln\left(\frac{e_0 \times \ln(\sigma_v)}{w_n}\right) - 0.9013 \times \left(\frac{w_n}{e_0^2}\right)^{\frac{1}{2}} + 1.404 \times 10^{-5} \times \left(\frac{\sigma_v}{e_0^2}\right) + 9.798 \times 10^{-3} \times w_n^{\frac{3}{2}} - 1.524 \times e_0^{\frac{1}{2}} \times \sin(e_0) \times (e_0 + 8.848) + 11.21 \quad (4.4)$$

La surface de réponse 3D a été utilisée pour examiner l'effet individuel et cumulatif de l'interaction mutuelle entre les variables. Cette représentation permet d'analyser la nature géométrique de la surface, les maxima et les minima de la réponse. La figure 4.28 montre qu'il existe une forte interaction entre l'indice des vides initial et la contrainte verticale. En effet, la surface de réponse indique que l'indice de compression diminue progressivement avec la diminution de l'indice de vide initial justifiant la non-linéarité avancée par certains auteurs. La valeur maximale de l'indice de compression secondaire obtenue est de 5.1×10^{-3} correspondant à une contrainte verticale de 3100 kPa et un indice des vides initial de 1.01.

Pour l'interaction entre la teneur en eau, l'indice des vides initial et le coefficient de compression secondaire, la surface de réponse de la figure 4.29 montre que l'indice de compression secondaire augmente progressivement avec l'augmentation de la valeur de l'indice des vides initial. Ce coefficient semble évoluer dans le sens inverse de la teneur en eau. La valeur maximale de l'indice de compression secondaire 5×10^{-3} est obtenue pour une teneur en eau au voisinage de 3% et un indice des vides initial de 1.02. D'après les résultats obtenus, le modèle développé semble être performant dans la prédiction de l'indice de compression secondaire avec un coefficient de corrélation R de 0.99. Quant à l'erreur moyenne absolue, elle n'excède pas les 0.04. Le présent modèle développé est retenu pour la prédiction de l'indice $C\alpha$.

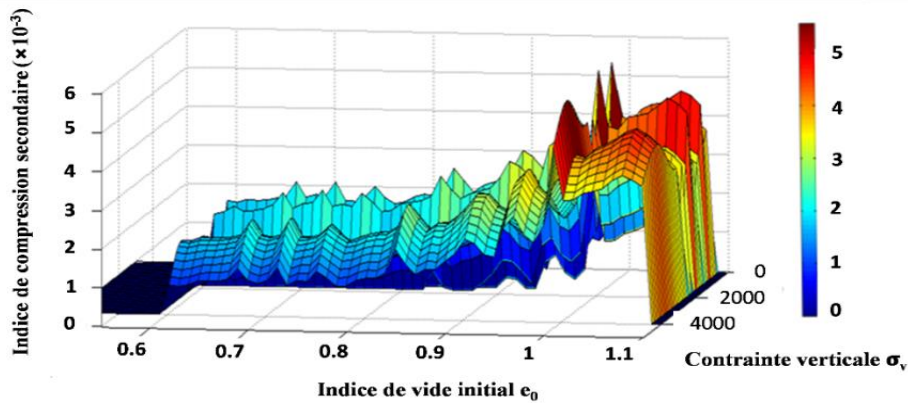


Figure 4.28 Visualisation globale de l'évolution de $C\alpha$ en fonction e_0 et σ_v




Figure 4.29 Visualisation globale de l'évolution de $C\alpha$ en fonction e_0 et w_n

2.2.4.3 Comparaison entre MGGP et NN-PSO

Les performances des deux modèles utilisés pour la prédiction de l'indice de compression secondaire C_α sont données dans le tableau 4.9 sur la base du paramètre MAE.

Tableau 4.9 Comparaison entre les modèles NN-PSO et MGGP

w_0	σ_0	e_0	Mesuré	Prédit NN-PSO	Prédit MGGP	Erreur NN-PSO	Erreur MGGP
66.8	22.29	1.000	1.67996	1.76148	1.69124	0.08152	0.01128
27.2	401.88	0.730	0.91599	0.80122	0.90529	0.11477	0.01070
70.5	10.92	1.040	1.97876	2.03187	1.98276	0.05311	0.00400
67.6	11.93	1.020	1.69676	1.84929	1.68983	0.15253	0.00693
27.3	206.43	0.755	0.83646	0.78890	0.84641	0.04756	0.00995
70	19.66	1.000	1.93996	2.02533	1.97326	0.08537	0.03330
27.7	1616.18	0.700	1.26872	1.17794	1.26349	0.09079	0.00523
61	22.79	0.950	1.63796	1.54331	1.62312	0.09465	0.01484
93.6	202.98	0.843	4.97607	4.83140	4.98582	0.14467	0.00975
79.9	27.56	0.990	2.92526	3.02732	2.89603	0.10206	0.02924
MAE						0.09670	0.01350

Les résultats obtenus montrent une grande cohérence entre les données expérimentales et les résultats de prédiction. Ceci reflète la grande précision des modèles prédictifs développés par apprentissage automatique et l'approche hybride PSO-NNA, les moyennes des erreurs absolues équivalentes sont respectivement égales à 0.0135 et 0.0967. Dans le domaine de l'ingénierie, ces erreurs sont très acceptables. La qualité de ces résultats est due principalement aux intervalles de variation des inputs qui correspondaient au domaine d'apprentissage. Pour les situations à faible teneur en eau naturelle (moins de 30%), la meilleure approche est la MGGP. Cette dernière a donné des solutions plus proches de l'optimum global. Lorsque le taux de teneur en eau naturelle augmente (environ de 70%), la technique NN-PSO génère des erreurs plus élevée, les résultats sont donc moins bons que ceux fournis par la MGGP. Ceci signifie que l'utilisation des paramètres ayant une faible corrélation est beaucoup pénalisante et qu'à partir d'un faible nombre d'entrées, le problème devient trop complexe. Cependant, elle présente de très bonnes propriétés de convergence au voisinage du minimum, ce qui peut s'avérer rapide en termes de temps de calcul.

3 Identification des paramètres par l'analyse inverse

Actuellement la méthode numérique la plus utilisée pour résoudre les problèmes géotechniques est la méthode des éléments finis (FEM). Cette méthode discrétise un milieu continu en lui attribuant une loi de comportement. Cette loi est caractérisée par des paramètres constitutifs, évalués à partir des essais expérimentaux au laboratoire et/ou in-situ. La détermination de ces paramètres pose des difficultés majeures à cause notamment de la représentativité des sols prélevés sur le site de construction et du fort remaniement induit par les opérations de forage et d'extraction. Tous ces points montrent que la validité des résultats de calcul par éléments finis est limitée par les incertitudes sur les paramètres introduits dans le modèle. Pour répondre à cette problématique, nous avons développé une méthode d'identification de paramètres, basée sur le principe de l'analyse inverse. Cette forme d'analyse consiste à caler le modèle numérique sur les données expérimentales par modification itérative des valeurs d'entrée jusqu'à ce que l'écart entre les résultats expérimentaux et numériques soit minimal. Ainsi, il est proposé ici d'étalonner le modèle constitutif avancé Soft Soil Creep Model (SSCM) sur la base des paramètres considérés dans le processus

d'optimisation à savoir l'indice de compression modifié (λ^*), l'indice du gonflement modifié (κ^*), l'indice du fluage modifié (μ^*), la cohésion (c), l'angle de frottement (ϕ), la perméabilité verticale (k_v) et la perméabilité horizontale (k_h).

3.1 Procédure d'analyse inverse

La méthode d'analyse inverse développée dans cette étude consiste à résoudre numériquement un problème géotechnique par des simulations éléments finis successives à partir de paramètres mécaniques. Le modèle numérique du sol est calé sur les données expérimentales par modifications itératives des valeurs des paramètres d'entrée du modèle jusqu'à ce que les valeurs en sortie reproduisent au mieux les données observées (Figure 4.30). La première étape de la procédure d'optimisation consiste à se donner un problème géotechnique et à lui associer un modèle numérique.

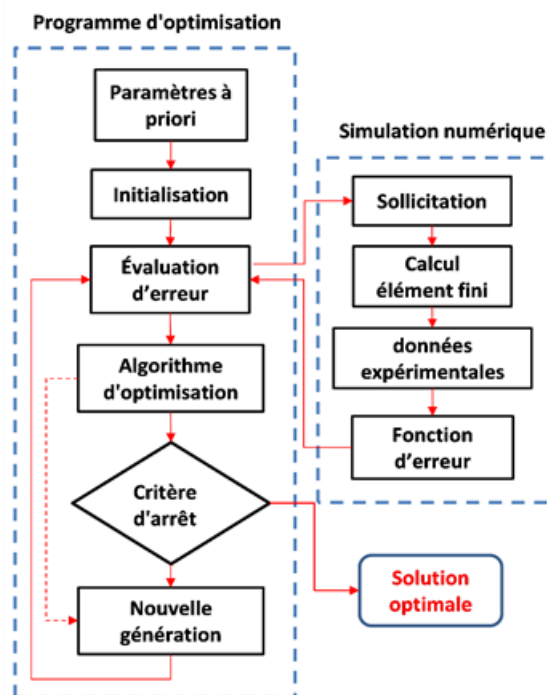


Figure 4.30 Principe d'identification par méthode numérique directe.

Pour la méthode d'optimisation, nous avons choisi d'utiliser un algorithme génétique. Cet algorithme traite une population d'individus, chaque individu représente un jeu de paramètres. Les valeurs maximale et minimale de chaque paramètre (P_{max} , P_{min}) sont déterminées par la méthode énumérative. Des opérateurs de sélection, croisement et mutation, sont appliqués aux générations d'individus successives afin d'en créer de nouveaux (Figure 4.31). Une sélection de type élitiste de 1/3 a été utilisée pour former une population parente, puis pour former une population enfant, l'opérateur de croisement avec un taux de 2/3 et l'opérateur de mutation avec un taux de 0.09, seront appliqués à l'individu parent. L'ensemble « population parents » et « population enfants » forme une nouvelle génération, le processus d'optimisation se répète, jusqu'à l'obtention d'un bon individu qui satisfait le critère d'arrêt.

La figure 4.31 montre qu'un problème donné doit être modélisé numériquement par un calcul éléments finis. Pour cette étude, nous avons choisi le code Plaxis. En fonction des sollicitations imposées au modèle et des paramètres régissant le modèle constitutif de sol, une réponse numérique est calculée. Cette réponse numérique est ensuite comparée aux données expérimentales

disponibles. Cette comparaison se traduit par le calcul de l'écart entre les données observées et les valeurs calculées, par le biais de la fonction erreur F_{err} ci-dessous.

$$\min F_{err} = \sum_i^n (U_{si} - U_{ei})^2 \quad (4.5)$$

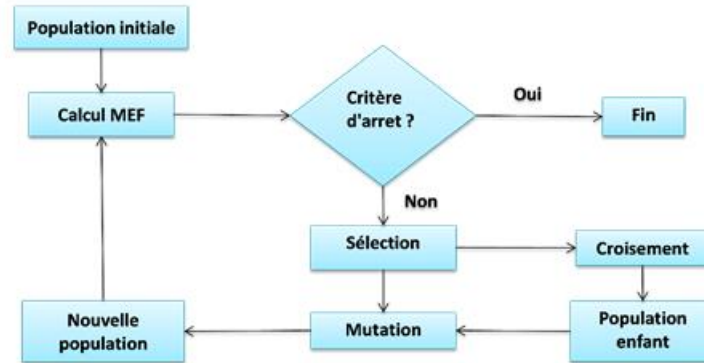


Figure 4.31 Schéma de principe d'optimisation par algorithme génétique.

3.2 Etude paramétrique.

Pour avoir une idée sur l'influence individuelle des paramètres du modèle SSCM, nous avons réalisé numériquement plusieurs simulations œdométriques sur un échantillon axisymétrique de 5 cm de largeur et 5 cm de hauteur, dans des conditions non drainées. Cette étape est nécessaire pour une bonne justification du classement des paramètres en fonction de leur degré d'influence. Les paramètres considérés dans cette étude sont les paramètres avec lesquels le modèle Soft Soil Creep Model a été étalonné (λ^* , κ^* , μ^* , c , ϕ , k_v et k_h). Dans un premier temps, nous avons effectué une analyse de type OAT (One At a Time). Celle-ci considère uniquement l'effet de la variation d'un seul paramètre sans prendre en compte l'interaction avec les autres paramètres du modèle.

Les figures 4.32, 4.33, 4.34, 4.35 et 4.36 présentent l'évolution des tassements calculés en fonction du temps pour les différentes valeurs des paramètres du modèle λ^* , κ^* , μ^* , c , ϕ , k_v et k_h .

La figure 4.32, montre un aperçu global sur le degré d'importance de l'indice de compression modifié. La comparaison va porter en premier lieu sur l'intervalle de temps [0 – 0.02] jours. On remarque qu'après quelque minute, les courbes commencent à se disperser. Il s'avère que lorsque l'indice λ^* diminue, le tassement augmente progressivement. Donc, le tassement évolue inversement avec la diminution de l'indice λ^* . Pour l'intervalle de temps [0.02 – 7] jours, un renversement de l'évolution a été enregistré à 0.025 jours et les tassements commencent d'évoluer avec l'augmentation de l'indice de compression λ^* . Lorsque l'indice varie de 0.05 à 0.2 le tassement augmente de +220%, ce qui montre clairement l'influence de l'indice de compression modifié sur le comportement des sols.

La figure 4.33 montre que pour un temps inférieur à 0.002 jours, l'augmentation de l'indice du gonflement modifié induit une augmentation du tassement instantané. Cette augmentation est de l'ordre 95% en passant d'un indice de 0.02 à 0.04 et de 50 % lorsque on passe de 0.04 à 0.06 et enfin une augmentation de 33% pour le passage de 0.06 à 0.08. Sur l'intervalle de temps [0.002 - 0.02] jours, le sol a conservé presque le même comportement sous l'effet de l'indice de gonflement modifié, les courbes gardent les mêmes écarts. Au-delà de 0.02 jours, les courbes simulées avec des indices inférieurs à 0.02 génèrent des écarts très rapprochés (soit environ 3.42%). Sous l'effet des indices supérieurs à 0.02, l'écart est plus important, il atteint les 9%.




Figure 4.32 Variation du tassement en fonction λ^*




Figure 4.33 Variation du tassement en fonction κ^*

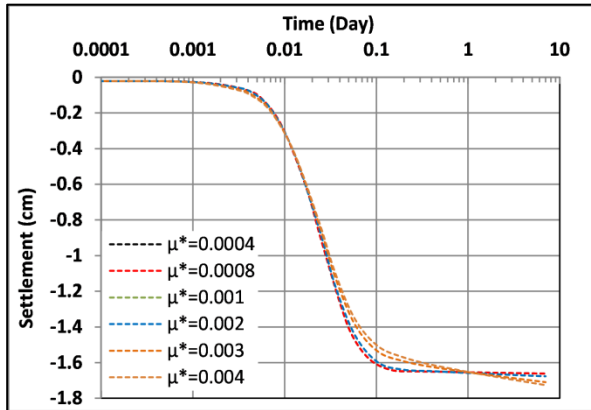


Figure 4.34 Variation du tassement en fonction μ^*




Figure 4.35 Variation du tassement en fonction C




Figure 4.36 Variation du tassement en fonction ϕ




Figure 4.37 Variation du tassement en fonction k_h, k_v

La figure 4.34 montre l'effet du paramètre μ^* sur le tassement calculé. Dans une première partie, les comparaisons des courbes sur l'intervalle du temps $[0 - 0.002]$ jours montrent que l'accroissement du coefficient de fluage modifié n'a pas exercé une influence appréciable sur le tassement. Une diminution du paramètre μ^* dans l'intervalle $[0.002 - 0.3]$ jours, s'est traduit par une augmentation du tassement, avec néanmoins un écart plus faible au départ, cet écart évolue d'une manière croissante ensuite. Cette croissance n'est pas proportionnelle à μ^* , c'est-à-dire que lorsque μ^* passe de la valeur 0.004 à la valeur 0.0004 (soit 10 fois moins), le tassement n'augmente que de 1.2 millimètre (soit environ 6.66%). Par contre, dans l'intervalle $[0.3 - 7]$ jours, il se produit un renversement entre les courbes. Les tassements simulés avec de faibles valeurs (μ^* inférieur à 0.02) se stabilisent et restent parallèles dans leurs grandes lignes. Les tassements simulés avec des valeurs supérieures à 0.02 divergent nettement en fonction du temps et suivent une pente descendante.

La figure 4.35 représente l'étude paramétrée du tassement en fonction de la cohésion. Deux points d'inflexion sont enregistrés dans l'intervalle [0.0001 - 0.015] jours. Cela montre que le tassement ne suit pas la même évolution que la cohésion et qu'il peut augmenter ou diminuer dans le temps, mais toujours dans de faibles proportions. Par contre, sur l'intervalle [0.02 - 0.1] jours, la diminution de la cohésion cause une accélération du tassement. Cela engendre des amplitudes plus importantes, soit un tassement allant de 7 à 20 millimètres. Au-delà de 2 jours, la vitesse du tassement se stabilise à un certain seuil et les pentes du fluage ne montrent pas de différence notable.

Pour l'angle de frottement, la figure 4.36 montre que ce dernier n'a pas une importance considérable dans l'intervalle de temps [0.0001 - 0.015] jours, sa variation a généré des profils presque identiques. Par contre, dans l'intervalle de temps [0.015 - 7], la croissance de φ engendre des écarts plus importants quand ce dernier dépasse 20° . Aussi, le doublement de l'angle de frottement φ de 20° à 40° produit une augmentation de 7.3 mm (soit environ 57%).

Les simulations effectuées pour étudier l'influence de la perméabilité sur le tassement sont représentées sur la figure 4.37. Les simulations ont été effectuées avec la condition $k_h = k_v$. Cette figure montre que la vitesse de tassement a varié de façon significative quand le coefficient de perméabilité est passé de 10^{-5} à 10^{-2} m/jour. Durant cette période, le coefficient de perméabilité maximal (10^{-2} m/jour) provoque un tassement maximal qui vaut 15 millimètre. Le coefficient minimal (10^{-5} m/jour) produit un tassement quasiment nul, il se chiffre à 0.5 millimètre. Au-delà de 2 jours, les tassements associés aux coefficients 10^{-2} , 10^{-3} , 10^{-4} et 10^{-5} m/jour sont sensiblement les mêmes et varient entre 17.2 et 17.4 millimètres.

Les plages de déplacement obtenu par la variation paramétrique des différents paramètres sont illustrées sur la figure 4.38. La figure montre que lorsqu'on fait varier l'un des paramètres étudiés, le déplacement produit se situe dans plusieurs zones et se déplace suivant l'une des trois directions du plan polaire (x , z , θ). Par exemple, la variation de l'indice μ^* a fait déplacer la courbe du tassement dans trois zones différentes, 1, 2 et 5. Alors que la variation des paramètres λ^* , κ^* , c et φ déplacent la courbe dans les zones 1, 3 et 4 avec des directions différentes. La variation des coefficients de perméabilité (k_h et k_v) a déplacé la courbe du tassement dans les zones 1, 2 et 4. Comme la courbe du tassement a une forme sigmoïde très caractéristique, il est donc très important d'utiliser les paramètres qui affectent le sol selon les directions, verticale (x), horizontale (z) et rotationnelle (θ) afin de caler cette relation de manière très flexible avec les résultats expérimentaux. En égard de ces résultats, il semble nécessaire d'adopter les sept paramètres pour une meilleure gestion et efficacité de l'optimisation par l'algorithme génétique.

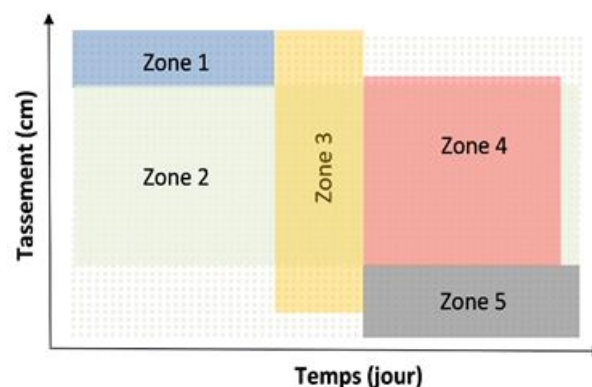


Figure 4.38 Plages de déplacement obtenu par la variation paramétrique.

3.3 Optimisation par l'algorithme génétique

Ce processus d'optimisation commence par la génération d'une population initiale aléatoire de 150 individus. Puis, un calcul par éléments finis est exécuté. Le tassement mesuré in situ est ensuite intégré dans le programme pour trouver la fonction erreur F_{err} . Les mesures in situ doivent être considérées avec une incertitude expérimentale. Par ailleurs, la fonction erreur définie pour l'optimisation est pondérée par un coefficient Δu_i relatif à l'erreur expérimentale. Si la condition d'arrêt n'est pas satisfaisante, les trois mécanismes d'optimisation par l'algorithme génétique (sélection, croisement et mutation) sont appliqués pour former une nouvelle génération. Ensuite, les mêmes étapes que la génération précédente sont répétées jusqu'à ce que F_{err} soit minimale. Avant de procéder à l'optimisation des paramètres du modèle SSCM du remblai multicouche réel, il a été jugé nécessaire de commencer l'application par des simulations simples afin que les ajustements nécessaires aux paramètres de l'algorithme génétique puissent être apportés rapidement, ceci permet de contrôler la procédure de l'analyse inverse. Le choix s'est porté sur deux essais œdométriques, le premier ayant une seule couche de sol (MC) et la seconde comporte deux couches de sol (DC).

3.3.1 Essai œdométrique Monocouche (MC)

Le processus d'optimisation proposé a été mené dans le but d'estimer d'une façon précise les paramètres μ^* , λ^* , κ^* , c , ϕ , k_h et k_v . La procédure commence par un calcul du tassement d'un limon en utilisant la méthode des éléments finis. La cellule œdométrique de dimension 2,5 x 1,9 cm est analysée en condition axisymétrie de révolution et en considérant une loi de comportement de type SSCM pour le sol. Puisque l'étude tient compte de la compression secondaire, une contrainte verticale constante de 100 kPa a été appliquée pendant 10 jours. Les paramètres fournis pour cette loi de comportement sont donnés dans le tableau 4.10 ci-dessous.

Tableau 4.1 Paramètres du model SSCM avant identification (Arabet, 2011).

Couche	κ^*	μ^*	λ^*	K_0^{nc}	M	c [kN/m ²]	ϕ [°]	$k_v=k_h$ [m/s]
Limon	0.019	1×10^{-8}	0.034	0.5	0.724	32	16	1.22×10^{-8}

L'étude a révélé, comme le montre la figure 4.39, un décalage important entre la courbe du tassement observé et celui simulé. En d'autres termes, une stabilisation de la courbe simulée a été observée. Ceci pourrait s'expliquer par la valeur extrêmement faible de l'indice de fluage modifié qui a été considéré dans cette simulation. Il faut noter que ce paramètre est rarement déterminé par des essais expérimentaux lors de campagne géotechnique. Il est souvent estimé à partir de relations empiriques, ce qui rend la validité des résultats des calculs par éléments finis limitée. C'est dans ce contexte qu'est née la problématique de l'analyse inverse en géotechnique.




Figure 4.39 Comparaison entre le tassement observé et simulé avant identification.

Lors de la deuxième étape, une optimisation par un couplage entre le code éléments finis et le code de calcul Matlab a été effectuée. Après 100 générations, la courbe simulée avec les nouveaux paramètres identifiés paraît presque confondue avec celle observée comme le montre la figure 4.40.




Figure 4.40 Comparaison entre le tassement observé et simulé après identification.

Les paramètres qui ont permis cette concordance sont donnés dans le tableau 4.11 ci-dessous.

Tableau 4.2 Paramètres du modèle SSCM après identification.

Couche	κ^*	μ^*	λ^*	K_0^{nc}	M	c [kN/m ²]	ϕ [°]	$k_v=k_h$ [m/s]
Limons	0.0212	6.50×10^{-6}	0.0305	0.5	0.724	31	15.3	1.22×10^{-8}

L’algorithme a préféré de garder la perméabilité telle quelle et a ajusté itérativement les valeurs de μ^* , λ^* , κ^* , c, ϕ . Ceci signifie que ces paramètres corrigent au mieux la forme de la courbe du tassement. Le tableau 4.11 que ci-dessus indique que l’indice du fluage modifié (μ^*) déterminé par l’approche développée ici est largement supérieur à celui obtenu par Arabet (2011), ce qui montre que la valeur utilisée par ce dernier est sous-estimée pour une argile limoneuse.

Les résultats obtenus par l’optimisation par l’algorithme génétique montrent que, effectivement cette dernière est une approximation satisfaisante du comportement réel du. Pour la suite et par rapport aux résultats obtenus, des corrections notables au critère d’arrêt et aux quelques paramètres de l’algorithme génétique sont apportés pour assurer une convergence rapide vers la bonne solution du problème et d’éviter de tomber dans un optimum local.

3.3.2 Essai œdométrique double couche (DC)

Dans cette phase, une simulation œdométrique d’un échantillon hétérogène à double couches dans des conditions œdométriques, non drainées et axisymétrique de 5 cm de rayon et 8 cm de hauteur, a été menée. Les caractéristiques du matériau étudié sont résumées dans le tableau 4.12 suivant.

Tableau 4.3 Paramètres du modèle SSCM avant identification selon Ganesalingam (2013)

Couche	κ^*	μ^*	λ^*	K_0^{nc}	M	c [kN/m ²]	ϕ [°]	$k_v=k_h$ [m/j]
0 – 40 (mm)	0.0358	0.0018	0.0836	0.67	1.13	1	27.3	1×10^{-4}
40 – 80 (mm)	0.0199	0.0014	0.0794	0.67	1.13	1	29.5	1.1×10^{-4}

Une surcharge de compression uniformément répartie de 9 kPa a été appliquée et l’échantillon sera consolidé durant une journée. La géométrie et les conditions aux limites du problème sont récapitulées sur la figure 4.41.




Figure 4.41 Géométrie et conditions aux limites du modèle

Les résultats représentés sur la figure 4.42 mettent en évidence une divergence entre les deux courbes de tassement. Le décalage enregistré augmente avec le temps. La différence est de l'ordre de 60%. Ceci signifie que les résultats du calcul par éléments finis sont limités par les incertitudes sur les paramètres introduits dans le modèle. A partir de ces résultats, le calibrage du modèle par un algorithme génétique s'impose.




Figure 4.42 Comparaison entre le tassement observé et simulé avant identification.

Après 100 générations successives, l'algorithme génétique a permis de ramener la variance à 0,21%, ce qui est relativement faible. Les paramètres identifiés sont donnés dans le tableau 4.13 ci-dessous et les résultats des tassements calculés sont représentés sur la figure 4.43.

Tableau 4.4 Paramètres du modèle SSCM après identification.

Couche	κ^*	μ^*	λ^*	K_0^{nc}	M	c [kN/m ²]	ϕ [°]	$k_v=k_h$ [m/j]
K100	0.0338	0.0011	0.1251	0.67	1.13	1	29.5	2.71×10^{-4}
K70	0.0245	0.00092	0.1191	0.67	1.13	1	27.3	2.53×10^{-4}

La figure montre que la courbe des tassements mesurés est pratiquement confondue avec celle des tassements simulés. L'identification des paramètres à partir de l'algorithme génétique est donc très concluante, ce qui montre l'intérêt de cette application.




Figure 4.43 Comparaison entre le tassement observé et simulé après l'identification.

Vu ces résultats intéressants, la méthode va être appliquée à un multicouche constitué par un remblai réel en France. Il s'agit du remblai B de Cubzac les Ponts et dont les mesures sont disponibles sur une longue période.

3.3.3 Remblai B de Cubzac les Ponts

3.3.3.1 Présentation de l'ouvrage

Les Laboratoires des Ponts et Chaussées ont construit quatre remblais, notés A, B, C et D, sur un sol compressible depuis les années 1970. Le remblai B est le plus ancien des quatre remblais édifiés pour l'étude de la consolidation des argiles molles (Lepidas et Magnan, 1990). Ce site expérimental est situé à environ 30 km de Bordeaux, en bordure de l'autoroute A10. Le sol du site est une argile molle, grise, très organique avec une teneur en eau naturelle assez élevée et il présente une bonne homogénéité. Le tableau 4.14 ci-dessous donne quelques paramètres de ce sol.

Tableau 4.5 Propriétés physiques, chimiques et hydriques du sol Michali (1994)

w_n	LL	PI	S_r (%)	k (m/s)	MO (%)
100-200	100-200	50-100	100	$2.10^{-10} - 2.10^{-9}$	5-25

La coupe géotechnique permet de distinguer trois couches principales :

- ❖ de 0 à 1,5 m : une couche d'argile molle surconsolidée, correspondant aux limites de fluctuation de la nappe ;
- ❖ de 1,5 à 3,5 m : une couche d'argile très organique et très compressible, légèrement surconsolidée;
- ❖ de 3,5 à 9 m : une couche d'argile molle organique légèrement surconsolidée.

Le matériau du remblai est constitué de gravier et de sable grossier, d'un poids volumique de 21 kN/m³. La hauteur totale du remblai est de 2,3 m et sa construction a duré 6,3 jours, du 9 au 15 octobre 1975.

3.3.3.2 Modélisation du remblai B et le sol de fondation

Le remblai B de Cubzac-les-Ponts fournit une base de données exceptionnelle avec le suivi du tassement et des pressions interstitielles sur près de 20 ans (Nguyen Pham, 2008). L'objectif est alors d'utiliser le modèle SSCM pour simuler le comportement de ce remblai.

➤ Maillage et conditions aux limites

Le site a été modélisé d'une manière identique à celle effectuée par Michali (1994), les neuf mètres du sol compressible se trouvant sous le remblai B ont été modélisés par 6 couches. Les dimensions de ce remblai et sa fondation sont illustrées sur la figure 4.44 ci-dessous.




Figure 4.44 Maillage et conditions aux limites.

Le maillage utilisé dans les calculs représente la moitié du remblai et du sol de fondation car le problème est symétrique. La fondation a été maillée sur 45 m de longueur, c'est-à-dire 5 fois la demi-largeur du remblai et 9 m de hauteur avec les caractéristiques déterminées par la coupe géotechnique et les essais effectués lors des sondages sous le remblai. Le phasage de modélisation en 10 couches dans un temps de 6,3 jours a été choisi en conformité avec le calendrier de la construction réelle du remblai. Les conditions aux limites prises en compte dans ce calcul sont les suivantes :

- Drainage par les faces inférieure, supérieure et droite du massif de sol.
- Déplacements horizontaux nuls en bas et sur les faces latérales du massif de sol.
- Déplacements verticaux nuls en bas du massif de sol.

L'état initial est caractérisé par une distribution hydrostatique des pressions interstitielles, avec une nappe phréatique placée à (-1 m) par rapport à la surface de l'argile.

➤ Méthodologie de calcul

Le mécanisme de déplacement d'un remblai peut être considéré comme un problème de déformations planes. Dans le cas du remblai B de site expérimental du Cubzac-les-Ponts, le rapport longueur-largeur est de l'ordre de 3, ceci nous a conduits à choisir une modélisation axisymétrique plutôt qu'une modélisation en déformation plane. Le maillage représente 5 fois la longueur du remblai. Le calcul est effectué en trois étapes :

- ❖ La première étape : Lors de cette étape, les couches de sol sont supposées se consolider sous leur poids propre. La durée de cette consolidation a été choisie à 7000 jours.
- ❖ La deuxième étape : Lors de cette phase, c'est la construction du remblai B qui a été modélisée. Le chargement simulé a été activé couche après couche d'une façon à suivre le calendrier de construction de ce remblai. Le calendrier de chargement est représenté sur la figure 4.45 ci-dessous.
- ❖ La troisième étape : Dans cette étape, c'est la fondation qui se consolide sous les différentes charges. La durée de consolidation a été fixée à 2407 jours. Dans cette durée, le temps de construction du remblai y est inclus (6,3 jours).




Figure 4.45 Calendrier de construction du remblai B (Michali, 1994).

Le modèle de fluage adopté pour la simulation du remblai et de sa fondation est le modèle « SSCM ». Les paramètres du modèle utilisés sont illustrés dans le tableau 4.15, l'angle de dilataance (Ψ) pour l'ensemble elle est nul.

Tableau 4.6 Paramètres du modèle SSCM avant identification selon Michali (1994).

Couche	κ^*	μ^*	λ^*	K_0^{nc}	M	c (kN/m ²)	ϕ [°]	k_v (m/j)	K_h (m/j)
0 – 1 (m)	0.0180	0.0082	0.123	0.67	1.13	32	19	4.32×10^{-4}	1.30×10^{-3}
1 – 2 (m)	0.0290	0.0132	0.198	0.67	1.13	32	19	4.32×10^{-4}	1.30×10^{-3}
2 – 4 (m)	0.0570	0.0162	0.243	0.48	1.62	12	31	2.59×10^{-4}	8.64×10^{-4}
4 – 6 (m)	0.0300	0.0118	0.176	0.48	1.65	1	31	2.59×10^{-4}	8.64×10^{-4}
6 – 8 (m)	0.0300	0.0130	0.196	0.46	1.75	1	33	8.64×10^{-5}	2.85×10^{-4}
8 – 9 (m)	0.0416	0.0120	0.181	0.46	1.72	1	33	8.64×10^{-5}	2.85×10^{-4}

➤ Résultats et analyses

Il est important de souligner que les hypothèses et les conditions aux limites sur lesquelles repose la modélisation ont été acceptées par plusieurs auteurs (Michali, 1994; Lepidas and Magnan, 1990; Al Husein, 2001).

Après avoir paramétré le modèle par les valeurs du tableau 7, les résultats simulés du tassement présentent un écart qui augmente progressivement au fur et à mesure qu'on avance dans le temps comme le montre la figure 4.46. Ceci peut être dû à une mauvaise connaissance des propriétés mécaniques des sols (Magnan et al, 1999), car les essais de laboratoire sont basés sur de petits échantillons de sol plus ou moins remaniés et ne sont pas nécessairement représentatifs du massif de sol dans son ensemble. On note que la courbe du tassement générée à partir de cette modélisation est identique à celle obtenue par Al Husein (2001), ce qui nous permet d'affirmer la maîtrise de l'outil et d'aborder l'analyse inverse.




Figure 4.46 Comparaison entre le tassement observé et simulé avant identification.

3.3.3.3 Optimisation par l'algorithme génétique

Les bornes minimales et maximales de l'intervalle des paramètres sont spécifiées à l'aide d'une méthode énumérative afin de réduire le risque de trouver le minimum local plutôt que le minimum global. Il est noté que la fonction d'erreur converge vers une stabilisation après seulement 10 générations (Figure 4.47). Cela prouve que l'intervalle sélectionné a été correctement identifié pour cette optimisation.




Figure 4.47 Évolution de la moyenne de F_{err} sur chaque génération.

Les figures 4.48, 4.49, 4.50, 4.51, 4.52 et 4.53 représentent l'évolution des individus parents sur l'espace de recherche. Ces figures montrent que d'une population initiale tirée aléatoirement sur tout l'espace avec une erreur moyenne très élevée (figure 4.48), l'ensemble converge progressivement vers une zone optimale où F_{err} est faible. L'espace de représentation est à 3 dimensions, la cohésion, la perméabilité horizontale et la perméabilité verticale. Les deux premières générations (Figures 4.49 et 4.50) donnent une nouvelle représentation de la solution produite par l'algorithme génétique. Cette représentation tridimensionnelle illustre les meilleurs individus sélectionnés pour participer au croisement et à la mutation. Après l'avoir triée de manière croissante selon la fitness de ses individus, la 3^{ème} et la 4^{ème} génération, indiquent que l'exploration initiale de l'espace de recherche tend vers une solution, sa perméabilité verticale est comprise entre 2×10^{-4} et 8×10^{-4} m/s (Figures 4.51 et 4.52). Une réduction remarquable de la diversité de cette population a été signalé dans la 10^{ème} génération, le nuage de points identifié décrit une sphère sur l'espace de recherche (k_v , k_h , c), ce qui signifie que les individus parents se sont stabilisés sur une combinaison unique des paramètres solution pour laquelle F_{err} est minimale (Figure 4.53).

L'algorithme ajuste plus précisément les valeurs d'entrée qui sont utiles pour la convergence. D'après les résultats du tableau 4.16, l'algorithme, trouve qu'il serait nécessaire d'avoir la même configuration de la cohésion pour assurer une grande souplesse. L'algorithme a connu une baisse considérable, après neuf itérations et 1350 calculs éléments finis, tous les individus parents vérifient le critère d'arrêt ($F_{err} \leq 4.6\%$).

Tableau 4.7 Paramètres du modèle SSCM après identification.

Couche	k_h [m/j]	k_v [m/j]	c (kN/m ²)	ϕ (°)	λ^*	κ^*	μ^*
0 – 1 (m)	$3.98.10^{-3}$	$4.32.10^{-4}$	32	18.8	0.111	0.064	0.015
1 – 2 (m)	$9.94.10^{-3}$	$4.32.10^{-4}$	32	18.9	0.176	0.039	0.013
2 – 4 (m)	$5.54.10^{-3}$	$2.68.10^{-4}$	12	30.9	0.190	0.054	0.011
4 – 6 (m)	$9.75.10^{-3}$	$2.95.10^{-4}$	1	30.95	0.150	0.031	0.014
6 – 8 (m)	$9.93.10^{-3}$	$8.64.10^{-5}$	1	32.9	0.170	0.035	0.015
8 – 9 (m)	$7.20.10^{-2}$	$8.64.10^{-5}$	1	32.9	0.140	0.052	0.014




Figure 4.48 Population initial




Figure 4.49 Première génération

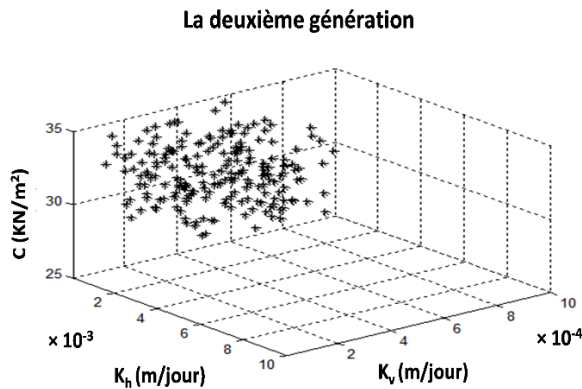


Figure 4.50 Deuxième génération




Figure 4.51 Troisième génération




Figure 4.52 Quatrième génération




Figure 4.53 Dixième à la dernière génération

La figure 4.54 présente la variation en fonction du temps du tassement mesuré et celui simulé de la dernière génération. Elle montre que les valeurs des tassements calculés se rapprochent des valeurs mesurées. En conclusion, l'approche offre l'avantage d'être très précise pour autant qu'elle ne reste pas coincée dans un minimum local. Cette précision a été atteinte en un temps relativement court, ce qui montre que l'approche permet une bonne exploitation du domaine de recherche. Ainsi, la méthode d'identification développée se présente comme un bon outil d'aide à l'identification des paramètres. Elle donne accès aussi à une gamme de variation caractéristique de chaque paramètre.




Figure 4.54 Comparaison entre le tassement observé et simulé après identification

4 Conclusion

Les modèles de régression sont des outils statistiques les plus habituellement mis en œuvre pour l'étude de données multidimensionnelles. Cependant, ces modèles sont très sensibles à la multi-colinéarité qui peut engendrer de graves instabilités sur certaines estimations obtenues par la méthode des moindres carrés ordinaires. Ces instabilités résultent de difficultés purement numériques liées à l'inversion des matrices qui sont presque singulières. La multi-colinéarité se présente souvent lorsqu'un grand nombre de variables explicatives sont incluses dans le modèle et que certaines d'entre elles fournissent des informations similaires. D'une manière générale, l'estimation obtenue dans ces conditions génère une variance très grande. En l'occurrence, lorsque la multi-colinéarité est présente dans l'ensemble des variables explicatives, et que celle-ci est indépendante de l'interprétation des variables et des erreurs de mesures, ce serait alors les réseaux de neurones artificiels qui devrait être préférée. L'apprentissage d'un réseau neuronal est

généralement réalisé par la minimisation de la fonction d'erreur. La plupart des méthodes d'entraînement, telles que la rétro-propagation de gradient et les algorithmes de gradient conjugué, sont basées sur la descente de gradient. Ces méthodes ont obtenu un grand succès dans de nombreuses applications. Cependant, l'un des problèmes souvent rencontrés lors de l'apprentissage des réseaux de neurones est la convergence vers un optimum local. Une solution a été proposée ici pour résoudre ce problème, c'est l'utilisation des algorithmes génétiques (GA) et les essais particulaires (PSO) pour effectuer cet apprentissage. Les deux algorithmes choisis s'appliquent facilement aux problèmes de plusieurs dimensions avec une convergence très rapide. Les résultats obtenus ont montré leurs efficacités d'exploration et la qualité de la recherche. Cependant, l'analyse par le réseau de neurones artificiels (RNA), par l'apprentissage hybride (NG) ou par la combinaison réseau de neurones-essaim particulaires (NN-PSO) manque de transparence, la sortie est obtenue sous forme de valeurs numériques «boîtes noires». C'est cette raison qui nous a conduits à utiliser la dernière version de la programmation génétique basée sur la programmation génétique multi-gènes (MGGP). Cette version a montré certaines performances quand elle a été appliquée à des problèmes techniques complexes. Des études comparatives entre la MGGP et d'autres algorithmes d'apprentissage ont permis de démontrer la grande robustesse de celle-ci face à des problèmes avec des données manquantes, ou encore sa performance sur des problèmes dont la forme de la solution est méconnue (Kobashigawa et al., 2009). En plus, la MGGP est capable de proposer des équations mathématiques concrètes que les réseaux de neurones ou d'autres techniques ne peuvent dans aucun cas les prédire.

Pour l'identification des paramètres des modèles constitutifs des sols (SSCM ici) par analyse inverse, l'algorithme génétique a montré sa performance. Les résultats obtenus pour le remblai B montrent qu'à partir d'une population initiale uniformément répartie sur l'espace de recherche, l'optimum a été obtenu après neuf générations pour les 50 générations du programme, ce qui montre que le processus d'optimisation est capable d'identifier une solution du problème avec une bonne précision et un coût de calcul raisonnable. Le problème majeur dans l'utilisation de cette méthode d'identification est le temps de calcul, chaque identification nécessite de quelques heures à plusieurs jours de calculs. Cette méthode est donc d'autant plus pertinente, par rapport aux méthodes de gradient, que le nombre de paramètres à identifier est important. Il est important de garder à l'esprit, que comme dans toute méthode numérique, les résultats doivent être interprétés avec précautions. Une expertise géotechnique reste nécessaire pour sélectionner correctement les paramètres du sol d'un modèle.

CHAPITRE 5

PREDICTION DU TASSEMENT A LONG TERME

1 Introduction

La prévision du tassement des sols fins compressibles a toujours posé des difficultés aux géotechniciens à cause des incertitudes qui l'entourent. Malgré l'amélioration des modèles numériques et expérimentaux ces dernières années (Brand et Brenner, 1981), il existe encore des différences significatives entre les tassements prédits et ceux observés. Un exemple illustratif de cette différence a été signalé en Coré du Sud où le tassement prédit est de 1,5 à 3 fois inférieur à celui observé (Chung et al., 2009; Park et al., 2010). Les difficultés proviennent essentiellement de la variabilité spatiale des propriétés du sol, des incertitudes liées à leurs déterminations (Bjerrum, 1967; Terzaghi et al. 1996) et aussi à la simplicité des modèles utilisés. Si le modèle linéaire unidimensionnel de Terzaghi reste encore utilisé, il est jugé irréaliste car il ne tient pas compte de la dépendance du temps et de l'espace de la perméabilité et du coefficient de consolidation (Huat, 1996). Pour mieux estimer ce tassement et réduire ces différences, de nouvelles approches ont été proposées comme la méthode semi-empirique d'Asaoka ou le modèle hyperbolique. Ces méthodes posent des problèmes d'efficacité que ça soit en matière du choix du pas de temps de discrétisation ou du degré de consolidation à partir duquel ces méthodes peuvent être valides (Edil et al. 1991; Tan and Chew 1996). Pour améliorer ces estimations, des modèles de prédiction sous forme d'équations mathématiques ont été proposés. Nous pouvons citer le modèle exponentiel, le modèle logistique, le modèle de Gompertz et le modèle d'Usher. Ces modèles présentent l'avantage d'avoir des expressions analytiques d'utilisation facile, néanmoins leurs performances restent limitées (Lei et al., 2014; Jiang et al., 2016). Face au développement des techniques d'apprentissage et les résultats prometteurs qu'elles fournissent, il est proposé dans cette partie de la thèse un travail qui s'appuie sur les résultats publiés par certains auteurs et qui utilisent ces outils pour estimer le tassement des sols fins. Parmi ces travaux, il y'a ceux de Hu et al. (Hu et al., 2019), qui en hybridant le modèle d'optimisation par essais particulières avec la technique de régression vectorielle (SVR) ont obtenu des résultats remarquables avec une moyenne absolue de l'erreur (MAPE) inférieure à 2,5 %. Liu et al. (Liu et al., 2019) ont montré que le réseau de neurone (NN) optimisé par l'algorithme génétique (AG) avec simple objectif fournissait des résultats supérieurs à ceux du système d'inférence neuro-floue adaptatif (ANFIS) et à ceux d'un réseau conventionnel de neurones artificiels (ANN). Jiang et al (2016) ont combiné le modèle Gompertz avec le modèle logistique et ont montré que l'utilisation de plusieurs fonctions mathématiques donne une grande confiance dans la prédiction. En conséquence et sur la base de ce qui a été dit ci-dessus, trois solutions pour prédire le tassement et la pression interstitielle sont proposées. La première consiste à développer un modèle fortement non linéaire (MTN) généré par deux algorithmes avancés, l'algorithme génétique et l'essaim particulaire. La deuxième, concerne la mise en place de la dernière version de la programmation génétique multigène (MGGP) qui génère des solutions plus faciles à mettre en pratique. Pour la troisième solution, un réseau de neurones récurrents de type long short-term memory (LSTM) a été adopté. Ce dernier est capable d'apprendre des relations non linéaires complexes. Cette solution vise à implémenter un réseau de neurones profonds révolutionné (CNN) qui alterne entre couches de convolution et couches d'agrégation. Les approches présentées ci-dessus ont été appliquées à deux couches de sols, la couche Ma12 de l'île I et la couche Ma13 de l'île II de l'aéroport international du Kansai (Figure 5.2).

2 Présentation du site et caractéristiques des sols

2.1 L'aéroport international du Kansai

L'aéroport international du Kansai a été construit à 5 km de la côte de Senshu, sur des îles artificielles dans la baie d'Osaka à l'ouest du Japon. La construction de l'île I a commencé en 1987 et la mise en service l'a été en 1994. La construction de l'île II a commencé en 1999 et a été mise en service en 2007 (Nakase, 1987; Nkiac, 2012). La profondeur maximale jusqu'au substratum rocheux dépasse les 3000 m, comme le montre la figure 5.1.




Figure 5.1 Profil géologique d'Osaka (Mesri et al. 2015).

Le profil sédimentaire sous-marin du site est illustré à la figure 5.2. Le profil comprend les couches d'argile marine du pléistocène Ma0-Ma12 et la couche d'argile marine de l'holocène Ma13. Les couches d'argile marine alternent avec les couches de sable Dtc et les argiles non marines Doc (Figure 5.2).




Figure 5.2 Profil sédimentaire sous-marin du site de Kansai (Mesri et al. 2015)

2.1.1 Observations sur le comportement du remblai

L'évolution des tassements des fonds marins sous la zone de poldérisation (gagnée sur la mer) et les couches d'argile du pléistocène (les couches Ma) a été suivie à l'aide d'un tassomètre magnétique basé sur la technique du BBR (British Building Research). Le système est composé d'un tube d'accès avec un tube externe cannelé, d'anneaux magnétiques et d'une section inférieure télescopique avec un anneau de référence et une tête de suspension. Les anneaux magnétiques (cibles) sont fixés dans le sol à l'extérieur du tube d'accès, à des profondeurs où les mouvements sont susceptibles de se produire (Figure 5.3). Les anneaux magnétiques se déplacent avec le sol le long de l'axe du tube d'accès. Les lectures sont effectuées à distance, en descendant la sonde à détection magnétique dans le tube d'accès.




Figure 5.3 Schéma du tassomètre magnétique (Furudoï, 2010).

La mesure de la pression interstitielle a été effectuée à l'aide de piézomètres pneumatiques, dit FPC. Ces derniers sont particulièrement bien adaptés à la surveillance à court ou à long terme et offrent des mesures automatisées grâce à un enregistreur de niveau piézométrique. Dans cette contribution, on ne s'intéresse qu'à deux couches seulement, la couche argileuse Ma12 qui se trouve dans l'île I et la couche argileuse Ma13 qui se trouve dans l'île II. Les figures 5.4, 5.5, 5.6 et 5.7 donnent les tassements et les pressions interstitielles mesurés de ces couches.




Figure 5.4 Tassement mesuré de la couche Ma12 de l'île I (Mesri et al. 2015)




Figure 5.5 Tassement mesuré de la couche Ma13 de l'île II (Mesri et al. 2015)




Figure 5.6 Pression interstitielle mesurée de la couche Ma12 de l'île I (Mimura et Jeon, 2013)




Figure 5.7 Pression interstitielle mesurée de la couche Ma13 de l'île II (Mesri et al. 2015)

2.1.2 Propriétés physico-chimiques et hydriques du sol

Les propriétés du sol à savoir, la teneur en eau initial (w_0), la limite de plasticité (LP), la limite de liquidité (LL), l'indice de plasticité (IP), la fraction argileuse (CF), La densité des grains solides (Gs), l'indice des vides initial (e_0), la perméabilité verticale (k_v) et le coefficient de perméabilité (C_k) des deux couches étudiées sont présentées dans le tableau 5.1 ci-dessous.

Tableau 5.1 Propriétés physiques et chimiques du sol (Mesri et al. 2015)

Layer	Sub-layer	w_0 (%)	LP (%)	LL (%)	IP (%)	CF (%)	Gs (-)	e_0 (-)	k_v (m/s)	C_k (-)
Ma13	1	110	35	102	67	-	2.67	2.933	2.3E-08	1.5
	2	96	35	99	64	-	2.67	2.560	1.1E-08	1.3
	3	86	32	90	58	-	2.67	2.293	5.0E-09	1.1
	4	74	30	78	48	-	2.67	1.973	2.2E-09	1.0
	5	66	30	66	36	-	2.67	1.760	1.0E-09	0.9
Ma12	1	79	38	104	65	35	2.66	2.101	1.2E-09	1.1
	2	55	29	76	47	39	2.66	1.453	5.4E-10	0.7

3 Prévision des tassements à long terme

L'étude sera entamée par la méthode graphique d'Asaoka. Ensuite, c'est le modèle multi terme (MTM) généré et optimisé par les algorithmes génétiques et les essais particuliers qui sera appliqué. Par la suite, ce sont les techniques avancées tel que, la programmation génétique (MGGP), le réseau de neurones à mémoire court et long terme (LSTM) et le réseau de neurones à convolution (CNN) qui seront explorés avec les programmes élaborés. L'analyse de cette étude est divisée en trois cas, selon l'attribution des variables aux modèles.

a) Premier cas: Un seul paramètre d'entrée

Le premier cas consiste à analyser le tassement futur sur la base de son historique en utilisant seulement les mesures tassométriques. Les simulations avec une seule entrée sont effectuées pour toutes les méthodes proposées auparavant (la méthode graphique, les modèles mathématiques et les algorithmes avancés).

b) Deuxième cas: Deux paramètres d'entrée

Le deuxième cas est effectué d'une façon similaire que le premier mais avec une seconde entrée attribuée au chargement vertical en suivant le programme de chargement prévisionnel. Il est noté que la méthode d'Asaoka exige seulement les mesures du tassement. En conséquence, il n'est pas possible d'ajouter le chargement. Les modèles mathématiques optimisés par les algorithmes génétiques et les essais particuliers, s'appuie sur l'unique relation entrée – sortie (c'est-à-dire un système mono-variables). En conséquence, il n'est pas possible à mettre en œuvre ses modèles lorsque les systèmes étudiés possèdent plusieurs entrées.

c) Troisième cas: Multi-paramètres

Pour améliorer la performance et ajouter l'information manquante à nos réseaux, des indicateurs techniques ont été ajoutés à la dernière simulation. Ces indicateurs qui sont ; la moyenne mobile arithmétique (SMA), l'oscillateur génial (AO), l'accélération et décélération (AC), le taux de variation (ROC) et le momentum (M), aident à identifier les tendances et le comportement du tassement. Cette simulation est applicable seulement pour la programmation génétique (MGGP) et les techniques avancées (CNN, LSTM).

3.1 Prévision du tassement par la méthode d'Asaoka

La principale difficulté de cette méthode graphique réside en particulier dans la nécessité de traiter les données avec des intervalles de temps constant (Δt). Dans la pratique, cette condition est très rarement appliquée, elle nécessite une interpolation non linéaire pour discrétiser le temps de façon à obtenir des intervalles réguliers. Dans cette étude, nous avons choisi une équation polynomiale de degré six comme une solution appropriée pour aplanir ces obstacles. Le tassement obtenu a été extrait pour un intervalle de temps $\Delta t = 100$ jours. Notre choix s'est porté sur les recommandations de Pinto (2001) qui semblaient les mieux adaptées à notre objectif.

3.1.1 Résultats et validation de l'approche

3.1.1.1 Terminal 1

a) Premier cas

La figure 5.8 ci-dessous représente la construction d'Asoka avec un pas du temps égale 100 jours pour la couche Ma12 du terminal 1 de l'aéroport. Cette méthode donne une vitesse d'évolution du tassement beaucoup plus élevée que celle observée réellement. La courbe représentée sur la figure 5.9 donne un tassement de 0.8 m pour un temps $t = 1600$ jours. Ce tassement ne sera observé réellement qu'au bout d'un temps de $t = 2000$ jours.




Figure 5.8 Construction d'Asoka avec un pas de temps égal à 100 jours de la couche Ma12




Figure 5.9 Le tassement estimé par la méthode d'Asoka de la couche Ma12

3.1.1.2 Terminal 2

a) Premier cas

Le tassement final estimé graphiquement est de l'ordre de 10 m pour un incrément de temps égal à 100 jours (Figure 5.11). Cette écart significatif entre le tassement mesuré et observé est principalement dû au nombre de données insuffisant (1095 jours) utilisé pour tirer les meilleurs paramètres ajustant la courbe mesurée. En revanche, lorsque les courbes du tassement ne sont pas régulières la méthode d'Asoka n'amène pas de bonne prévision. Cet inconvénient montre bien la limitation de cette méthode graphique.




Figure 5.10 Construction d'Asaoka avec un pas de temps égal à 100 jours de la couche Ma13




Figure 5.11 Le tassement estimé par la méthode Asaoka de la couche Ma13

3.2 Prévision du tassement par MTM

3.2.1 Mise en application de la MTM

La procédure proposée consiste à combiner plusieurs formules des modèles mathématiques existants afin de donner une nouvelle formulation pour prédire le tassement à long terme. Le traitement du problème sera réalisé en deux phases. Comme indiqué sur l'organigramme de la figure 5.12, la première phase consiste à sélectionner deux ou trois parmi les modèles mathématiques disponibles pour lesquels la combinaison donne une erreur minimale en utilisant un algorithme génétique et un algorithme d'optimisation par essais particuliers. La deuxième phase consiste à optimiser les inconnues de l'équation (5.1) formée à l'étape 1.

En conséquence, le programme commencera par la sélection de deux ou trois modèles parmi les cinq modèles disponibles (modèle hyperbolique, modèle exponentiel, modèle logistique, modèle Gompertz et modèle Usher) pour former le modèle combiné de tassement suivant :

$$S_t = A (\text{Modèle 1}) + B (\text{Modèle 2}) + C(\text{Modèle 3}) + D \quad (5.1)$$

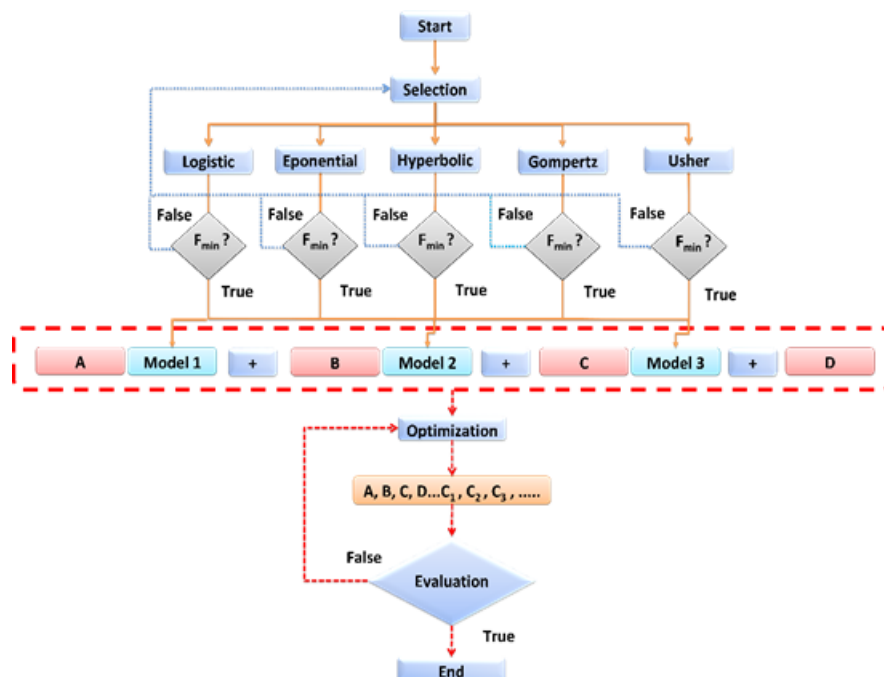


Figure 5.12 Organigramme du programme développé.

Ensuite, le programme générera aléatoirement une population initiale sur l'espace de recherche de chaque individu pour déterminer les constantes A, B, C et D de l'équation. Une évaluation de la fonction d'erreur sera effectuée. La fonction d'erreur évalue la différence entre les valeurs prédites par le modèle figurant à l'étape 1 et les valeurs mesurées. Quant à l'algorithme génétique, il commence par la création d'une génération aléatoire composée d'une collection de chromosomes. Normalement, la taille de la population initiale est de 100. Pour générer une population initiale, le programme prend au hasard au moins deux fonctions mathématiques parmi les fonctions définies, puis génère automatiquement la population initiale. Cette population particulière sera ensuite soumise aux opérateurs génétiques de sélection, de croisement et de mutation pour produire une nouvelle génération évoluée. Le processus d'évolution sera répété jusqu'à ce que l'erreur de la fonction de remise en forme devienne minimale (Equation 5.2).

$$\min F = \sum_t^n (S_t - [A. [Modele 1] + B. [Modele 2] + C (Modèle 3) + D])^2 \quad (5.2)$$

Pour l'algorithme de l'optimisation par essais particuliers (PSO), il se base sur le concept d'auto-organisation, concept qui suppose qu'un groupe d'individus peu intelligents peut posséder une organisation globale complexe grâce à des règles de déplacement très simples. Au départ de l'algorithme, chaque particule est positionnée aléatoirement dans l'espace de recherche du problème. Chaque itération fait bouger les particules en fonction de trois composantes : sa vitesse actuelle V(k), sa meilleure solution P(i) et la meilleure solution obtenue dans son voisinage P(g). Le processus continue jusqu'à ce que les particules convergent vers un minimum local.

3.2.2 Résultat et discussions

3.2.2.1 Terminal 1

a) Premier cas

Dans ce cas, le multi-terme optimisé par l'AG (MTM-AG) a sélectionné le modèle logistique et le modèle Gompertz comme une meilleure combinaison. Par contre dans le cas du multi-terme optimisé par PSO (MTM-PSO), le modèle Gompertz et le modèle Usher ont été retenus comme une meilleure solution. Le tableau 5.2 résume les équations obtenues.

Tableau 5.2 Fonctions obtenues à partir du modèle MTM

Modèles	Equations
MTM-AG	$S_t = A \times \left[\frac{c_1}{1+c_2 e^{-c_3 t}} \right] + B \times [c_4 \cdot \exp[-c_5 \cdot \exp(-c_6 \cdot t)]] + C \quad (5.3)$ <p>s_t: Tassement à l'instant t, A, B, C, c_1, c_2, c_3, c_4, c_5, c_6: Constants</p>
MTM-PSO	$S_t = A \times [c_1 \cdot \exp[-c_2 \cdot \exp(-c_3 \cdot t)]] + B \times \left[\frac{c_4}{[1+c_5 e^{-c_6 t}]^{\frac{1}{c_7}}} \right] + C \quad (5.4)$ <p>s_t: Tassement à l'instant t. A, B, C, c_1, c_2, c_3, c_4, c_5, c_6, c_7: Constants</p>

Après avoir déterminé les meilleures combinaisons possibles, la MTM commence à élaborer la prochaine phase du programme qui optimise et détermine les inconnus à l'aide de l'AG et du PSO.

Les fonctions de remise en forme sont évaluées par les fonctions d'écart type notées min F (Tableau 5.3). La capacité des modèles est déterminée par le calcul de l'erreur quadratique moyenne et du coefficient de détermination.

Tableau 5.3 Fonctions objectives.

Modèles	Paramètres	Les fonctions objectives
MTM-AG	s_t : Tassement à l'instant t A, B, C, c_1 , c_2 , c_3 , c_4 , c_5 , c_6 : Constants	$\min F = \sum_i^n \left(S_t - \left[A \times \left[\frac{c_1}{1+c_2 e^{-c_3 t}} \right] + B \times [c_4 \cdot \exp[-c_5 \cdot \exp(-c_6 \cdot t)]] + C \right]^2 \right) \quad (5.5)$
MTM-PSO	s_t : Tassement à l'instant t A, B, C, c_1 , c_2 , c_3 , c_4 , c_5 , c_6, c_7 : Constants	$\min F = \sum_i^n \left(S_t - \left[A \times [c_1 \cdot \exp[-c_2 \cdot \exp(-c_3 \cdot t)]] + B \times \left[\frac{c_4}{[1+c_5 e^{-c_6 t}]^{c_7}} \right] + C \right]^2 \right) \quad (5.6)$

Les modèles MTM-AG et MTM-PSO ajustent la courbe du tassement sur les 5400 premiers jours et prévoit le tassement en extrapolant cette courbe à des futurs pas de temps. Les courbes peuvent être hyperbolique, exponentiel, logistique, Gompertz, Usher ou combiné. Les deux algorithmes PSO et AG définissent le type de courbe qui correspond le mieux à chaque emplacement. Dans les 5400 jours, les résultats obtenus par les deux méthodes montrent une grande similitude dans les performances, soit environ un écart de 1.2 %, provenant du fait que les deux modèles ont adopté au début une forme de représentation presque exponentielle (Gompertz). Le choix du modèle logistique par l’algorithme génétique comme un deuxième terme du modèle MTM-AG, a passé d’un écart de 1.2 % à 12 % entre la période 5400 jours et 7900 jours (Figure 5.13). L’algorithme PSO a choisi le modèle Usher comme deuxième terme du modèle MTM-PSO, ce qui mené l’erreur de 1.2 % à 2 % entre la période 5400 jours et 7900 jours (Figure 5.14). Cela montre l’efficacité du modèle Usher pour la prédiction à long terme.




Figure 5.13 Tassement mesuré et prédit par la méthode MTM-AG de la couche Ma12




Figure 5.14 Tassement mesuré et prédit par la méthode MTM-PSO de la couche Ma12

3.2.2.2 Terminal 2

a) Premier cas

Le modèle multi-terme optimisé par l’AG (MTM-AG) a choisi le modèle hyperbolique et le modèle Gompertz comme meilleure combinaison pour la prédiction du tassement à court et à long terme. Par contre, le modèle multi-terme optimisé par PSO (MTM-PSO) a sélectionné le modèle logistique et le modèle Gompertz comme meilleure solution. Les équations sont présentées dans le Tableau 5.4 ci-dessous :

Tableau 5.4 Fonctions obtenues à partir du modèle MTM

Modèles	Equations
MTM-AG	$S_t = A \times \left[c_1 + \frac{(t-c_2)}{[c_3+c_4.(t-c_2)]} \right] + B \times [c_5 (1 + c_6. \exp(-c_7. t))] + C \quad (5. 7)$ <p>s_t: Tassement à l'instant t. A, B, C, c_1, c_2, c_3, c_4, c_5, c_6, c_7: Constants</p>
MTM-PSO	$S_t = A \times [c_1 (1 + c_2. \exp(-c_3. t))] + B \times \left[\frac{c_4}{1+c_5e^{-c_6t}} \right] + C \quad (5. 8)$ <p>s_t: Tassement à l'instant t. A, B, C, c_1, c_2, c_3, c_4, c_5, c_6: Constants</p>

Après avoir déterminé les meilleures combinaisons, la MTM entame la deuxième phase du programme qui optimise et détermine les inconnus à l'aide de l'AG et du PSO. Les fonctions fitness sont représentées sur le tableau 5.5.

Tableau 5.5 Fonctions objectives.

Modèles	Paramètres	Les fonctions objectives
MTM-AG	s_t : Tassement à l'instant t A, B, C, c_1 , c_2 , c_3 , c_4 , c_5 , c_6 , c_7 : Constants	$\min F = \sum_i^n \left(S_t - \left[A \times \left[c_1 + \frac{(t-c_2)}{[c_3+c_4.(t-c_2)]} \right] + B \times [c_5 (1 + c_6. \exp(-c_7. t))] + C \right] \right)^2 \quad (5. 9)$
MTM-PSO	s_t : Tassement à l'instant t A, B, C, c_1 , c_2 , c_3 , c_4 , c_5 , c_6 : Constants	$\min F = \sum_i^n \left(S_t - \left[A \times [c_1 (1 + c_2. \exp(-c_3. t))] + B \times \left[\frac{c_4}{1+c_5e^{-c_6t}} \right] + C \right] \right)^2 \quad (5. 10)$

Les deux algorithmes PSO et AG ont sélectionné le modèle exponentielle, cela signifie que le tassement suit une loi exponentielle. On note que le modèle MTM-PSO optimisé par l'algorithme PSO a donné une erreur minimale absolue de 0,0117 et un coefficient de détermination de 0,996, cela montre clairement la puissance de cet algorithme (Figure 5.16). Nous constatons un écart croissant entre le tassement observé et le tassement prédit par le modèle MTM-AG (Figure 5.15). Ceci veut dire que la sélection de la fonction hyperbolique par l'algorithme génétique est un mauvais choix. Cependant, il se peut que cette mauvaise décision soit due à la petite taille de la base d'apprentissage (1095 jours).




Figure 5.15 Tassement mesuré et prédit par la méthode MTM-AG de la couche Ma13




Figure 5.16 Tassement mesuré et prédit par la méthode MTM-PSO de la couche Ma13

3.3 Préviation du tassement par MGPP

3.3.1 Mise en équation et programmation de l'MGPP

L'ensemble des fonctions actif qui sont sélectionnées pour être dans les modèles développés sont les opérateurs arithmétiques (+, -, -, /, ×), les fonctions non linéaires (sin, cos, tan, exp, tanh, tanh, log, sqrt) et les opérateurs booléens. Les opérateurs génétiques permettent de créer de nouveaux individus au cours de l'évolution. Deux types d'opérateurs sont rencontrés, les opérateurs

de croisement et les opérateurs de mutation. Les opérateurs de croisement combinent deux individus parents pour créer un ou plusieurs nouveaux individus enfants en se partageant les gènes de leurs chromosomes. Pour les mutations, c'est tout un gène qui peut être substitué. La performance est mesurée à l'aide de la fonction fitness, qui compare les valeurs prédites et les valeurs mesurées. Nous avons choisi l'erreur quadratique moyenne "RMS" donnée par l'équation (5.11) ci-dessous comme indicateur pour valider le modèle:

$$RMS = \sqrt{\frac{\sum_{i=1}^N (P_i - A_i)^2}{N}} \quad (5.11)$$

Pour le 3^{ème} cas, on doit procéder à une transformation des données afin d'exprimer les indicateurs techniques en fonction du temps (t). Pour cela et à partir des 60 précédents jours (Δx), on établit la relation donnant Δx en fonction du temps (t) nommé (Δu) qui sera ajoutée au vecteur initial u_0 pour avoir un nouveau vecteur mis à jour. Le nouveau point de fonctionnement (Δx , Δu) est calculé en utilisant l'algorithme de MGGP, l'organigramme simplifié est montré sur la figure 5.17.

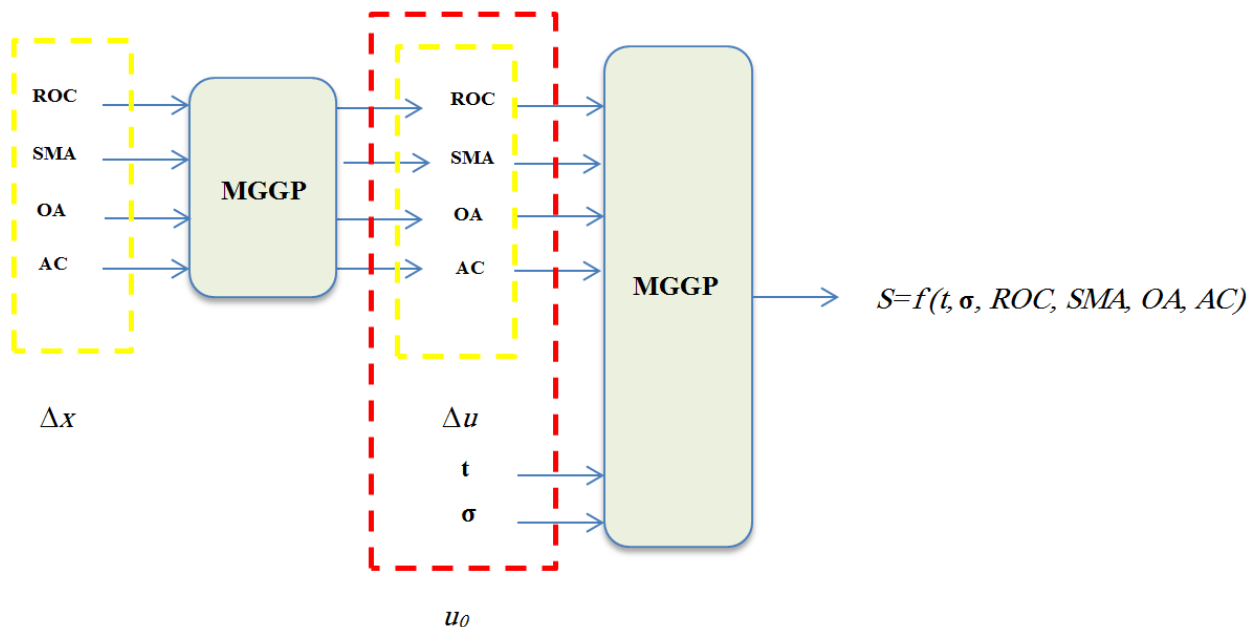


Figure 5.17 Fonctionnement de l'algorithme MGGP.

3.3.2 Résultats et validation du modèle

3.3.2.1 Terminal 1

a) Premier cas

Les résultats de cette simulation sont présentés sur la figure 5.18. Cette figure montre que lorsque le nombre de générations augmente, l'erreur quadratique moyenne diminue de manière sigmoïdale alors que l'erreur globale moyenne reste constante. Contrairement aux méthodes de régression classique, l'algorithme proposé augmente la chance de trouver des liaisons de nature complexe, il ne cherche pas la présence d'une relation linéaire ou non linéaire entre les variables dans les sous espaces. Mais il explore tout l'espace de recherche. Ceci lui permet de converger plus rapidement et plus précisément vers une solution de bonne qualité dans un laps de temps raisonnable.




Figure 5.18 Performances du modèle avec une seule variable (Ma12).

Le meilleur individu retenu présente un coefficient de détermination R^2 de 0,9975, un RMS de 0,0218. Le modèle obtenu à l’issue de cette optimisation est présenté par l’équation 5.12 ci-dessous :

$$S(t) = 0.1888 \times t^{1/2} - 0.09405 \times \ln(t) - 0.0004479 \times t^9 - 0.0006948 \times t - 0.2039 \quad (5.12)$$

Pour la phase du test, il convient de noter que l’écart entre le tassement prédit et le tassement mesuré augmente en fonction du temps, mais avec une vitesse suffisamment faible pour être acceptable (Figure 5.19). Ceci peut être expliqué par le nombre important de données qui ont assurés un bon déroulement de la phase d’apprentissage.




Figure 5.19 Tassement observé et prédit par le model MGGP-1input (Ma12).

b) Deuxième cas

L’intégration du chargement dans le modèle a traduit une diminution de l’erreur quadratique moyenne de l’ordre de 61% et une augmentation du coefficient de détermination autour de 2 %. La courbe de convergence pour le 1^{er} et le 2^{ème} cas sont semblables, il s’agit d’une stabilisation après la 50^{ème} itération (Figure 5.20). Aussi, la moyenne globale de l’erreur est très similaire à celle obtenue dans le 1^{er} cas (Figures 5.18 et 5.20).




Figure 5.20 Performances du modèle avec deux variables (Ma12).

Le coefficient de détermination R^2 est très proche de 1, ce qui prouve que le modèle est très précis. Le meilleur individu retenu présente un coefficient de détermination R^2 de 0,999, un RMS de 0,016. Plus le RMS est faible (proche de zéro), plus le tassement simulé par le modèle est proche de celui observé. Le modèle obtenu à l’issue de cette optimisation est présenté par l’équation (5.13):

$$S(t, \sigma) = 4.133 \times 10^{-5} \times (t^3 + 2 \times \sigma \times t^2)^{1/2} - 4.469 \times 10^{-8} \times |t^2 + \sigma| - 3.765 \times 10^{-5} \times t^3 + (t \times \sigma^2 + t \times \sigma)^{\frac{1}{2}} - 0.006177 \quad (5.13)$$

Le modèle non linéaire qui lie le tassement mesuré et le chargement aux tassements futurs a permet de diminuer considérablement la distance moyenne entre les observations et les prévisions. Cela nous amène à mettre en œuvre le modèle avec deux variables explicatives permettant de modéliser correctement le tassement à long terme (Figure 5.21).




Figure 5.21 Tassement observé et prédit par le modèle MGGP- 2 input (Ma12).

c) *Troisième cas*

Les indicateurs techniques ont donné lieu à une amélioration considérable de la phase d’apprentissage avec une baisse d’erreur de 99% par rapport au 2^{ème} modèle (deux variables explicatives). Selon la figure 5.22, on remarque que l’algorithme peut converger vers des configurations meilleures mais le nombre maximum d’itérations préfixé de 250 est atteint. On peut aussi voir qu’après la 200^{ème} itération, la dispersion de l’erreur globale se situe aux environs de l’axe des abscisses, c’est-à-dire autour de zéro. Ceci nous permet de conclure que l’estimation effectuée est excellente.




Figure 5.22 Les performances du model avec sept variables d'entré (Ma12).

Le modèle obtenu doit ensuite être employé pour estimer les valeurs de la variable expliquée sur de nouvelles observations. L'erreur qui nous intéresse pour l'utilisation d'un modèle n'est donc pas l'erreur d'apprentissage mais plutôt l'erreur de généralisation (phase de test). Dans cet exemple, le meilleur individu retenu présente une erreur quadratique moyenne de 0,056 qui est en moyenne trois fois supérieure à celle trouvée précédemment. Le modèle a perdu ses qualités de prédiction sur de nouveaux échantillons avec un écart remarquable. Cet écart augmente linéairement en fonction du temps (Figure 5.23). Ceci est dû probablement au sur-apprentissage qui est généralement provoqué par la mauvaise capacité à capturer des informations des données.




Figure 5.23 Tassement observé et prédit par le modèle MGGP- 7 input (Ma12).

Le modèle obtenu à l'issue de cette optimisation, est présenté par l'équation (5.14):

$$S(t, M, SMA, AC) = 0.5147 \times (M + SMA) + 0.000281 \times \ln(t) + ROC \times (0.5147 \times SMA + 0.001405) + (0.7422 \times \frac{M}{ROC}) + 1.999 \times t \times ROC^2 \times AC - 0.001784 \quad (5.14)$$

3.3.2.2 Terminal 2

a) Premier cas

Afin d'évaluer les performances des modèles MGGP développés, nous avons testé ce dernier sur une autre base de données, plus petite, qui ne dépasse pas les 1096 jours. Les résultats illustrés sur la figure 5.24 montrent que la courbe de convergence se stabilise après la 200^{ième} itération. Le modèle qui contient uniquement le tassement mesuré, a entraîné une mauvaise performance. On remarque également une grande dispersion de l'erreur moyenne globale le long des générations procéder vers des valeurs comprises entre 0.2 et 0.3 mètre.




Figure 5.24 Performances du modèle avec une seule variable (Ma13).

Le modèle engendre une erreur potentiellement grande en raison du nombre faible des données et aussi le nombre insuffisant des entrées. Les résultats de la figure 5.25 montrent que le modèle est très loin d'être représentative de la relation entre le tassement prédit et celui mesuré. Dans l'exemple présenté ci-dessus, le calcul du coefficient de détermination aboutirait à l'idée qu'il existe une corrélation positive (+0.599) mais non significative entre les deux variables. Cette corrélation résulte uniquement de l'influence des points exceptionnels générés par le modèle.




Figure 5.25 Tassement observé et prédit par le modèle MGPP- 1 input (Ma13).

Le meilleur individu retenu présente un coefficient de détermination R^2 égal à 0.599 et un RMS de 15.04. Le modèle obtenu à l'issue de cette optimisation est exprimé par l'équation (5.15) suivante:

$$S(t) = 0.1904 \times \sin\left(t^{\frac{1}{2}}\right) - 0.0558 \times (t) - 0.00005.846 \times 10^{-5} \times t^2 + 0.3176 \times t^{\frac{1}{2}} + 0.003491 \times t^{\frac{3}{2}} - 0.3102 \quad (5.15)$$

b) Deuxième cas

Après l'application du chargement au modèle, on a constaté une diminution remarquable des erreurs surtout l'erreur quadratique moyenne. Cette diminution du RMSE se stabilise après 60 itérations pour atteindre la même performance (Figure 5.26). Notre algorithme suit donc bien le changement dynamique des terminaux et converge assez rapidement. La forme de la dispersion des points de la moyenne fitness oscille finement autour de la valeur de 0.12 et se ressemble à une ligne. Ceci nous conduit à conclure que la précision obtenue par ce modèle est acceptable par rapport au précédent.




Figure 5.26 Performances du modèle avec deux variables (Ma13).

Le meilleur individu retenu dans ce cas présente un coefficient de détermination R^2 de 0,55 et un RMS de 2.129. Le modèle obtenu à l'issu de cette optimisation, est présenté par l'équation (5.16) ci-dessous:

$$S(t, \sigma) = 0.01811 \times (t + \sigma + \ln(t) + \ln(t)^2) - 0.3877 \times \left(t + \sigma + \frac{\sigma}{t}\right)^{\frac{1}{2}} - 2.368 \times 10^{-6} \times (2 \times t + \sigma) * (t + \sigma + \cos(\sigma)) + 1.892 \quad (5.16)$$

Lorsqu'on compare la courbe observée avec la courbe prédite, on note une divergence de plus en plus marquée en fonction du temps (Figure 5.27). Cela provient du dernier terme de l'équation obtenue, un terme dominant de haut degré qui conduit à la génération de tassements tendant vers l'infini lorsque le temps tend vers l'infini. Cela prouve que le modèle ne présente pas correctement la relation entre le tassement prédit, le tassement mesuré et le chargement.




Figure 5.27 Tassement observé et prédit par le modèle MGGP- 2 input (Ma13).

c) *Troisième cas*

Malgré le nombre limité de donnée, il est intéressant de noter que les indicateurs techniques ont amélioré significativement les performances du modèle. Ils ont enregistré une amélioration remarquable de la capacité d'apprentissage d'environ 46 %. Cependant, ces indicateurs n'ont pas influencé la vitesse de convergence, la stabilisation notée après la 50^{ème} itération est pratiquement la même que celle obtenue par le deuxième modèle (Figure 5.28).




Figure 5.28 Performances du modèle avec 7 variables. (Ma13).

En plus et pour ce même modèle, la dispersion fitness n’est pas stable. En effet, il est noté une grande variation de l’erreur avec des chiffres variant entre 0.1 et 0.5 mètre (Figure 5.29). Cette variation est probablement due au nombre limité de données. En effet, car si le modèle n’était pas correctement paramétré, la variation aurait augmentée sûrement avec les itérations.




Figure 5.29 Tassement observé et prédit par le modèle MGGP- 7 input (Ma13).

Le modèle proposé pour la prédiction du tassement offre une dépendance non-linéaire entre les indicateurs techniques, le chargement, le tassement mesuré et le tassement prédit avec un coefficient de corrélation de 0,602 et une erreur quadratique moyenne voisine de 0,06. Le modèle obtenu à l’issu de cette optimisation est présenté par l’équation (5.17) suivante :

$$S(t, M, SMA, AC) = 2 \times (SMA + \sin(\tanh(AC))) - 0.6965 \times AC - 0.09291 \times \sin(\exp(-t)) - 0.1858 \times \sin(M) - 0.3482 \times \exp(-M) + 0.3474 \quad (5.17)$$

3.4 Prévission du tassement par l’apprentissage profond

Il existe différents types de réseaux de neurones artificiels, le perceptron multicouche (MLP), les réseaux de neurones convolutionnels (CNN) et les réseaux de neurones récurrents (RNN). Ces derniers sont les plus appropriés pour la modélisation de données séquentielles. Dans cette section de ce chapitre, on se focalisera sur les réseaux de neurones convolutionnels (CNN) et le modèle LSTM (Long Short-Term Memory). Ce dernier est un type particulier de réseau de neurones récurrents très populaire pour ses performances dans la prédiction des données séquentielles.

3.4.1 Traitement de données

Les jeux de données sont séparés en un ensemble d'apprentissage et un ensemble de test, en suivant la séparation usuellement utilisée, un découpage qui obéit à un ratio de 70% des données pour l'apprentissage et 30% des données qui doivent servir au test. Le seul prétraitement utilisé dans nos expériences est la normalisation par la fonction "z-normalisation" sur les deux ensembles avec les moyennes et déviations standard de l'ensemble d'apprentissage pour chaque jeu de données. Pour les huit variables, les données d'apprentissage sont fournies en mois standard représenté par un vecteur de taille 30 jours. La première étape consiste à aplatir les données pour obtenir huit séries temporaires. Ensuite, il faut itérer sur les pas temporels et diviser les données sur des intervalles qui se chevauchent, chaque itération se déplace le long d'un pas temporel et prédit l'instant (jour) suivant (Figure 5.30).

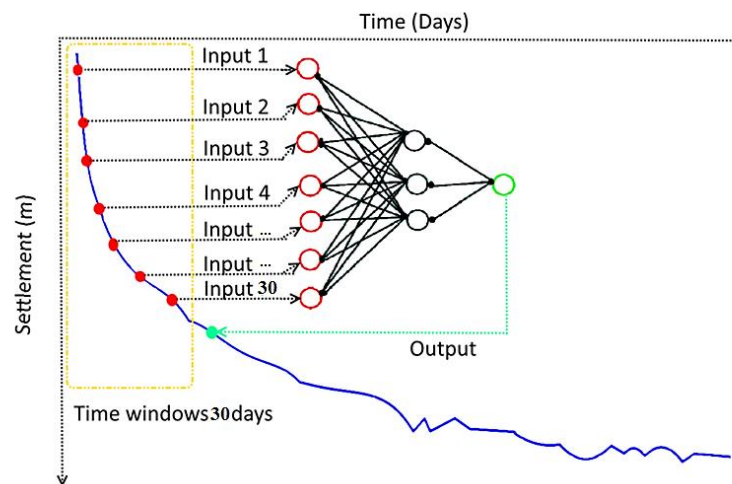


Figure 5.30 Jeu de données adopté pour les modèles LSTM et CNN.

3.4.2 Prédiction du tassement par réseau LSTM

Les réseaux de neurones artificiels traditionnels ne sont pas capables de stocker des informations. Pour ce faire, les chercheurs ont modifié la topologie pour produire des structures récurrentes qui alimentent les neurones et permettent le stockage de l'information. Le réseau LSTM, utilisé dans ici dans cette thèse, est une extension des réseaux de neurones récurrents. Ils sont conçus pour éviter le problème de dépendance à long terme en se souvenant de l'information pendant de longues périodes de temps et d'apprendre de nouvelles informations dans le présent. Les blocs LSTM contiennent des cellules de mémoire qui permettent de mémoriser une valeur pour une période de temps arbitraire et de l'utiliser si nécessaire. Il y a aussi une couche d'oubli qui peut effacer le contenu de la mémoire qui n'est pas utile. Tous les composants sont construits pour des fonctions différentiables et sont formés pendant le processus de rétro-propagation.

3.4.2.1 Mise en application du réseau LSTM

Pour l'application de cette technique, nous avons créé une couche LSTM qui contient 30 neurones. Les neurones de cette 1^{ère} couche sont connectés avec une deuxième couche qui contient 128 neurones. Nous avons ensuite ajouté une couche 'dense', c'est-à-dire une couche dans laquelle chaque neurone est connecté à tous les neurones de la couche précédente. Nous avons utilisé aussi la fonction 'Sigmoid' comme fonction d'activation. Elle est utilisée comme la fonction de déclenchement pour les 3 portes (in, out, forget), car elle produit une valeur entre 0 et 1. Cette dernière dispose de deux possibilités, soit aucun flux ne passe soit juste un complément de flux

d'information à travers les portes. Nous avons également utilisé l'algorithme d'optimisation 'Adam' pour mettre à jour les poids du réseau itératif en fonction des données d'apprentissage.

3.4.2.2 Résultats et validation du modèle

3.4.2.2.1 Terminal 1

a) Premier cas

Le modèle avec un seul paramètre d'entrée a offert une précision satisfaisante avec une erreur égale à 0.0238 et un coefficient de détermination égal à 0.999 (Tableau 5.6). La raison probable est le nombre acceptable des données expérimentales utilisées pour l'apprentissage, ce qui explique la faible erreur enregistrée.

Tableau 5.6 Évaluation du modèle LSTM-1 (Ma12).

Modèle	R ²		MAD		RMS	
	Train	Test	Train	Test	Train	Test
LSTM- 1 input	1	0.999	0.01302	0.024	0.0147	0.0238




Figure 5.31 Tassement observé et prédit par le modèle LSTM- 1 input (Ma12).




Figure 5.32 Performances du modèle LSTM- 1 input (Ma12).

D'après les résultats obtenus, on remarque dans la phase du test, la divergence entre le tassement prédit et celui observé. Ce dernier augmente en fonction du temps, ceci est la conséquence des cumuls des erreurs qui deviennent beaucoup plus importantes pour des estimations à long terme. Cette constatation montre la limite de ce résultat non significatif. (Figure 5.31).

b) Deuxième cas

L'intégration du chargement a permis d'améliorer les performances du modèle de plus de 14% (phase du test) alors que le coefficient de détermination obtenu est pratiquement le même que le cas d'un paramètre d'entrée. La précision est plutôt excellente surtout par rapport au modèle développé par la MGGP. La valeur de R² est voisine de 1, ce qui prouve que le modèle représente bien la relation entre le tassement mesuré, le chargement et le tassement prédit (Tableau 5.7).

Tableau 5.7 Évaluation du modèle LSTM- 2 input (Ma12)

Modèle	R ²		MAE		RMS	
	Train	Test	Train	Test	Train	Test
LSTM- 2 input	0.9996	0.9997	0.00816	0.02027	0.0105	0.0203

Ce deuxième modèle a enregistré une différence remarquable dans son niveau d'apprentissage, l'erreur quadratique moyenne a été diminuée de 28% (Figure 5.33), ce qui montre une autre fois la forte liaison entre la caractérisation du réseau LSTM et la qualité de l'information fournie pour l'apprentissage.




Figure 5.33 Tassement observé et prédit par le modèle LSTM-2 input (Ma12).




Figure 5.34 Performances du modèle LSTM-2 input (Ma12).

c) Troisième cas

La stratégie du renforcement par l'ajout d'informations présente un avantage important sur le modèle développé. Cependant, la convergence est plus lente pour atteindre la valeur optimale.

La première remarque qu'on peut tirer de la figure 5.35 est qu'il existe plusieurs parties dans la courbe avec des temps différents. Ce qui montre que cette configuration basée sur des indicateurs techniques rend l'apprentissage très difficile. L'erreur est ici plus grande que celles obtenues par les autres techniques.

Tableau 5.8 Évaluation du modèle LSTM- 7 input (Ma12)

Modèle	R ²		MAE		MSE	
	Train	Test	Train	Test	Train	Test
LSTM- 7 input	0.9998	0.9921	0.01458	0.01936	0.0164	0.0196




Figure 5.35 Tassement observé et prédit par le modèle LSTM- 7 input (Ma12).




Figure 5.36 Performances du modèle LSTM- 7 input (Ma12).

Malgré cette augmentation, l'erreur quadratique moyenne du test a connu une diminution de 3,4% (Tableau 5.8). S'appuyant sur l'analyse théorique de l'erreur, une nouvelle configuration peut

améliorer considérablement la qualité des réponses et donne au modèle la possibilité de corriger ces erreurs.

3.4.2.2.2 Terminal 2

a) Premier cas

D’après le tableau 5.9, les résultats sont satisfaisants et encourageants dans la perspective d’une analyse en termes de nombre de données. Par rapport au modèle MGGP, ce modèle a enregistré une diminution de 99.5% de l’erreur RMS, avec une augmentation de 65% du coefficient de détermination. Le processus d’analyse et la caractérisation se réalisent par la recherche d’une liaison reliant le tassement mesuré et le tassement prédit. Le coefficient de détermination obtenu est proche du 1, cela montre l’aptitude de l’approche LSTM pour le traitement des problèmes séquentiels.

Tableau 5.9 Évaluation du modèle LSTM- 1 input (Ma13)

Modèle	R ²		MAD		RMS	
	Train	Test	Train	Test	Train	Test
LSTM- 1 input	0.999	0.999	0.000163	3.296E-05	0.0612	0.0682

La figure 5.38 montre clairement que la convergence enregistrée tend vers la valeur zéro, ce qui montre que l’apprentissage du modèle est très bon. Les données choisies pour le test du modèle ont présenté une erreur quadratique moyenne faible qui vaut 0.0682, ce qui montre que le rendement du modèle est supérieur aux modèles précédents.




Figure 5.37 Tassement observé et prédit par le modèle LSTM- 1 input (Ma13).




Figure 5.38 Performances du modèle LSTM- 1 input (Ma13).

b) Deuxième cas

Avec l’implication et l’ajout du chargement, l’étude indique une amélioration significative de la performance prédictive avant et après l’utilisation du LSTM. D’après l’étude, LSTM a présenté une erreur de 0.0651 dans la prédiction du tassement (Tableau 5.10), tandis que la MGGP présente une erreur de 2.129. En outre, la conclusion principale est que la technique LSTM, en comparaison avec les autres méthodes, présente une meilleure sensibilité à la compréhension et à l’apprentissage. Cet avantage conduit d’emblée à une meilleure relation liant le tassement prédit, tassement mesuré et le chargement.

Tableau 5.10 Évaluation du modèle LSTM- 2 (Ma13).

Modèle	R ²		MAD		RMS	
	Train	Test	Train	Test	Train	Test
LSTM- 2 input	0.999	0.901	0.000142	6.136E-05	0.0574	0.0651

La forme de la courbe est également un facteur important à prendre en compte pour évaluer les modèles. A cause d'une augmentation de 2 à 3 mm dans les prédictions pour le temps compris entre 1350 et 1360 jours, les résultats deviennent plus difficiles à interpréter (Figure 5.39). La conclusion indique que la performance du LSTM a été moins affectée par le nombre limité des données (1094 jours), contrairement au MGGP dont la performance a été affectée pour le même nombre.




Figure 5.39 Tassement observé et prédit par le modèle LSTM- 2 input (Ma13).




Figure 5.40 Les performances du modèle LSTM- 2 input (Ma13).

c) Troisième cas

Le nombre de données qui a été employé pour le développement de ce modèle est faible (inférieur à 1100). L'indicateur statistique employé pour quantifier l'erreur (RMS) enregistre une valeur inférieure à celle obtenue par le modèle à deux paramètres (Tableau 5.11). Mais le modèle a généré une courbe qui n'épouse pas la même allure que celle mesurée.

Tableau 5.11 Évaluation du modèle LSTM- 7 input (Ma13).

Modèle	R ²		MAE		RMS	
	Train	Test	Train	Test	Train	Test
LSTM- 7 input	0.999	0.901	0.000142	6.136E-05	0.0548	0.0571

Avec les indicateurs techniques, une grande variation est remarquée entre la courbe simulée et la courbe prédite. On peut formuler la même remarque que précédemment, puisqu'il s'agit d'allures particulières qui apparaissent dans la phase d'apprentissage (Figure 5.41). Cela signifie que la configuration adoptée est insuffisante puisqu'elle ne contient pas assez de mémoire pour stocker les informations utiles.

Dans cette section, il sera procédé au développement d'un réseau neuronal convolutif pour la prédiction des séries temporelles. A partir d'un certain nombre de jours antérieurs du tassement, il faut prédire le tassement du jour suivant. Le nombre de jours précédents utilisés comme entrée définit la sous-séquence unidimensionnelle (1D) de données que le CNN lira et apprendra pour extraire des paramètres.




Figure 5.41 Tassement observé et prédit par le modèle LSTM- 7 input (Ma13).




Figure 5.42 Performances du modèle LSTM- 7 input (Ma13).

3.4.3 Prédiction du tassement par un réseau CNN

3.4.3.1 Mise en application du réseau CNN

La première partie du réseau est la partie convolutive qui fonctionne comme un extracteur de caractéristiques vectorielles. Un vecteur est passé à travers une série de filtres, ou noyaux de convolution, créant de nouvelles matrices appelées cartes de convolutions. Certains filtres intermédiaires réduisent la résolution de la matrice par une opération de maximum local. Au final, la sortie cette partie est branchée à l'entrée d'une deuxième partie qui est constituée de couches entièrement connectées (perceptron multicouche). L'architecture proposée dans cette étude repose sur plusieurs couches alternes entre couche de convolution et couche d'aggrégation (pooling). La couche de convolution est constitué de 16 filtres et un noyau de taille 3. Ceci implique que la séquence d'entrée de 30 jours sera lue avec une opération convolutionnelle de trois pas de temps à la fois et sera répétée 16 fois. Les couches d'aggrégation réduiront ces Caractéristiques (feature map) de 1/4 de leur taille avant que la représentation interne ne soit aplatie à un vecteur long. Ceci est ensuite interprété par une couche entièrement connectée avant que la couche de sortie ne prédit les sept jours suivants de la séquence (Figure 5.43).

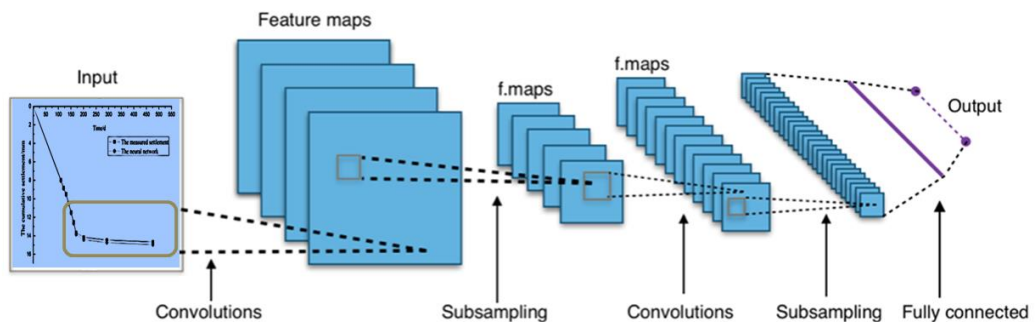


Figure 5.43 Topologie du modèle CNN utilisé.

Dans cette phase, c'est la fonction de perte d'erreur quadratique moyenne qui sera utilisée, celle-ci correspond à la métrique d'erreur RMS déjà choisie auparavant. Nous utiliserons aussi l'implémentation d'Adam de la descente stochastique de gradient et adapterons le modèle pour 100 époques avec un lot de taille 4. La petite taille des lots et la nature stochastique de l'algorithme impliquent que le même modèle apprendra un mappage légèrement différent des entrées aux sorties à chaque fois qu'il sera entraîné. Ce qui signifie que les résultats peuvent varier lors de l'évaluation du modèle.

3.4.3.2 Résultats et validations du modèle

3.4.3.2.1 Terminal 1

a) Premier cas

La première observation à propos des résultats obtenus concerne la prédiction du tassement. En effet, ils sont relativement satisfaisants avec un RMS égal à 0.0217 et un coefficient de détermination égal à 0.999 (Tableau 5.12).

Tableau 5.12 Évaluation du modèle CNN- 1 (Ma12).

Modèle	R ²		MAE		RMS	
	Train	Test	Train	Test	Train	Test
CNN- 1 input	0.999	0.999	0.01102	0.023	0.0167	0.0217

Ces résultats sont aussi équivalents à ceux obtenus par les modèles LSTM (Figure 5.44). Par ailleurs, la courbe de validation donne une courbe quasiment stable contrairement aux autres pour lesquelles beaucoup de fluctuations ont été notées (Figure 5.45).




Figure 5.44 Le tassement observé et prédit par le modèle CNN-1 input (Ma12).




Figure 5.45 Les performances du modèle CNN- 1 input (Ma12).

b) Deuxième cas

L'apprentissage profond supervisé des caractéristiques par le modèle ConvNet 1D aboutit à des meilleures performances que celles obtenues par les autres modèles d'apprentissage supervisé tel que LSTM et MGPP (Tableau 5.13).

Tableau 5.13 Évaluation du modèle CNN- 2 input (Ma12).

Modèle	R ²		MAE		RMS	
	Train	Test	Train	Test	Train	Test
CNN- 2 input	0.999	0.999	0.00830	0.001046	0.0122	0.0111

Avec l'intégration du chargement, le modèle commence par la modélisation de l'évolution temporelle aux deux échelles et vise ainsi à répondre aux performances attendues. Le chargement a permis d'améliorer les résultats d'environ 48%, avec une erreur quadratique moyenne de 0.0111, ce qui confirme que le modèle est très adapté pour les longues séquences (Figure 5.46).




Figure 5.46 Tassement observé et prédit par le modèle CNN-2 input (Ma12).




Figure 5.47 Performances du modèle CNN-2 input (Ma12).

c) Troisième cas

Tableau 5.14 Évaluation du modèle CNN- 7 input (Ma12).

Modèle	R ²		MAE		MSE	
	Train	Test	Train	Test	Train	Test
CNN- 7 input	0.999	0.998	0.01258	0.01989	0.0227	0.0105

La première remarque qu'on peut déduire de la figure 5.48 est l'absence des allures particulières déjà détectées dans les modèles LSTM (Figure 5.35 et 5.41). L'erreur d'apprentissage a augmenté de 46 % par rapport au modèle précédent, elle est passée de 0.0122 à 0.0227, ce qui montre que cette configuration basée sur des indicateurs techniques rend l'apprentissage difficile. Malgré ces difficultés, l'erreur de la phase du test a marqué une diminution de 5.7%. Ce qui prouve encore que l'ajout d'informations supplémentaires au réseau fournit une meilleure flexibilité.




Figure 5.48 Tassement observé et prédit par le modèle CNN- 7 input (Ma12).




Figure 5.49 Performances du modèle CNN- 7 input (Ma12).

3.4.3.2.2 Terminal 2

a) Premier cas

Etant donné que les données d'apprentissage ne portent que sur un faible nombre, les résultats obtenus ont été relativement satisfaisants (Figure 5.50). Ce modèle a fourni des résultats équivalents à ceux obtenus par LSTM.

Tableau 5.15 Évaluation du modèle CNN- 1 input (Ma13).

Modèle	R ²		MAE		RMS	
	Train	Test	Train	Test	Train	Test
CNN- 1 input	0.999	0.999	0.000103	3.176E-05	0.0538	0.0612

A noter que dans les simulations effectuées dans cette partie, aucun sur-apprentissage n'était observé. L'apprentissage s'est arrêté après 35 itérations pour lesquelles l'erreur moyenne sur les séquences d'apprentissage est restée la même (Figure 5.51).




Figure 5.50 Tassement observé et prédit par le modèle CNN- 1 input (Ma13).




Figure 5.51 Performances du modèle CNN- 1 input (Ma13).

b) Deuxième cas

Les résultats obtenus sont présentés sur la figure 5.52. L'erreur moyenne pour la phase d'apprentissage obtenue est de 0.0643, ce qui représente une amélioration de 4.7% par rapport aux résultats d'un seul paramètre d'entrée. Cette amélioration des performances concerne aussi la phase du test, avec une amélioration de +1.5% (Tableau 5.16).

Tableau 5.16 Évaluation du modèle CNN- 2 input (Ma13).

Modèle	R ²		MAE		RMS	
	Train	Test	Train	Test	Train	Test
CNN- 2 input	0.999	0.996	0.000140	6.076E-05	0.0514	0.0603




Figure 5.52 Tassement observé et prédit par le modèle CNN- 2 input (Ma13).




Figure 5.53 Performances du modèle CNN- 2 input (Ma13).

c) *Troisième cas*

Les paramètres R^2 et RMS montrent que le modèle proposé pour la prédiction du tassement a offert une précision acceptable (Tableau 5.17).

Tableau 5.17 Évaluation du model CNN- 1 input appliqué sur la couche Ma13

Modèle	R^2		MAE		RMS	
	Train	Test	Train	Test	Train	Test
CNN- 7 input	0.999	0.991	0.000129	6.798E-06	0.0548	0.0890

La comparaison du tassement prédit avec celui simulé montre la forme des deux courbes n'est pas identique (Figure 5.54). Pour la phase d'apprentissage et la phase du test, certains points sont éloignés des autres. En conséquence, ce modèle n'est pas le meilleur pour reproduire cette relation. Ces points ont une grande influence sur la précision du modèle.




Figure 5.54 Tassement observé et prédit par le modèle CNN- 7 input (Ma13).




Figure 5.55 Performances du modèle CNN- 7 input (Ma13).

3.5 La comparaison entre les approches développées MGGP, LSTM et CNN

Le tableau 5.18 donné ci-après récapitule les résultats obtenus par l'ensemble des approches appliquées dans cette étude. Pour déterminer les inconnues d'une façon optimale, ce sont les algorithmes génétiques et les essais particuliers qui ont été adoptés. Les résultats choisis sont ceux qui offrent une faible erreur quadratique moyenne. Dans la méthode d'Asaoka, il convient de suivre les tassements de consolidation suivant un pas de temps Δt constant. Suite à une série de tests selon divers pas du temps, le choix s'est porté sur 100 jours en raison de la faible erreur qu'ils ont fournis. Les performances ont été évaluées grâce à l'erreur quadratique moyenne (RMS) et le coefficient de détermination (R^2) pour toutes les approches.

Ce tableau montre que la précision est meilleure pour les modèles LSTM pour les deux sites Ma12 et Ma13. Le modèle CNN vient en deuxième position. Les modèles mathématiques mono et multi termes restent moins précis que les deux modèles précédents. Pour les modèles MGGP, la performance est idéale pour le terrain Ma12 entraînée par 5500 mesures. Une baisse importante est notée pour le terrain Ma13, elle est de 55%. A cause d'un mauvais apprentissage, ces modèles fournissent les plus faibles précisions. D'une manière générale, on peut affirmer qu'une réduction du nombre de données d'apprentissage (ici 1096 valeurs) génère une hausse du taux d'erreur. C'est ce qui est noté pour les modèles MGGP. En effet, en augmentant le nombre de paramètres d'entrée, leurs performances se trouvent significativement améliorées. Cela prouve aussi que le MGGP réagit et répond favorablement à l'ajout d'informations supplémentaires (Tang et al. 1991). Il faut noter que même si les modèles mathématiques (Uhsler, Comperz et logistique) aient offert des erreurs

acceptables à courte terme, le tassement final prédit par l’algorithme génétique (AG) est loin d’être réaliste (Figure 5.15). Pour les modèles LSTM et CNN, les coefficients de détermination R^2 ainsi que R^2 ajusté sont proches l’un de l’autre et les deux sont proches de 1. Ces valeurs sont suffisantes pour dire que les modèles ont offert une bonne précision, l’introduction des indicateurs techniques a réduit l’erreur quadratique moyenne et a ainsi amélioré l’efficacité des modèles.

Tableau 5.18 Comparaison entre les approches développées et les méthodes existantes.

Modèles		Ma12				Ma13			
		Train		Test		Train		Test	
		R^2	RMS	R^2	RMS	R^2	RMS	R^2	RMS
Asaoka	Evaluation	0.998	0.073	0.991	0.065	0.965	0.066	0.875	1.855
	Paramètres	A= 0.9602, B=0.0649				A= 0.9155, B=0.8752			
Compertz	Evaluation	0.993	0.041	0.894	0.0381	0.986	0.2237	0.913	0.179
	Paramètres	a=3.5212, b=0.00086, $s_f=1.4234$				a=6.9851, b=0.0049, $s_f=6.2395$			
Exponentiel	Evaluation	0.996	0.0325	0.877	0.1151	0.939	0.4614	0.931	2.8144
	Paramètres	a=1.0673, b=0.0003, $s_f=1.825$				a=1.1302, b=0.0010, $s_f=10.4158$			
Logistique	Evaluation	0.983	0.0666	0.886	0.0886	0.985	0.2352	0.843	0.0989
	Paramètres	a=12.7620, b=0.0014, $s_f=1.3563$				a=33.2269, b=0.0074, $s_f=5.9934$			
Uhsler	Evaluation	0.992	0.0449	0.83	0.0735	0.985	0.2285	0.865	0.081
	Paramètres	a=0.1825, b=0.001, c=0.0467, $s_f=1.3796$				a=12.3283, b=0.0066, c=0.6409, $s_f=6.0401$			
Hyperbolique	Evaluation	0.994	0.0367	0.868	0.1656	0.936	0.4728	0.867	4.2062
	Paramètres	a=2352.893, b=0.5003, $s_f=1.1624$, $t_0=2316.160$, $s_0=0.8529$				a=112.2457, b= 0.0608, $s_f=12.9198$, $t_0=522.09$, $s_0=3.4547$			
Gompertz-Logistic	Evaluation	0.983	0.0666	0.8860	0.0886	0.985	0.2352	0.843	0.0989
	Paramètres	a=27.0044, b= 0.0072, c=-0.0317, d=6.0583, e=2.2835, $s_f=6.1724$				a=9.8697, b=0.0057, c=-0.1883, d=0.7180, e=1.8203, $s_f=7.6100$			
MTM-AG	Evaluation	0.9986	0.018	0.8861	0.0440	0.8389	0.9890	0.9136	2.1300
	Paramètres	A=-0.6291, B=1.0285, C=-0.9249, $c_1=0.4103$, $c_2= 1.1969$, $c_3= 0.7776$, $c_4= 2.6938$, $c_5=0.9676$, $c_6=0.000508$.				A=0.0685, B=1.1776, C=-1.9775, $c_1=0.1211$, $c_2=1.4523$, $c_3=1.9848$, $c_4= 0.0043$, $c_5=-2.3824$, $c_6=0.2324$, $c_7=0.2210$.			
MTM-PSO	Evaluation	0.9994	0.0130	0.8928	0.0230	0.9859	3.4560	0.0159	0.1400
	Paramètres	A=1.0843, B=0.7778, C=0.3319, $c_1=-0.4185$, $c_2=0.1056$, $c_3=-0.00238$, $c_4=1.5164$, $c_5=0.9208$, $c_6=0.0008$, $c_7=0.1867$.				A=1.4452, B=1.8162, C=-1.7659, $c_1=-0.8466$, $c_2=0.4567$, $c_3=-0.0010$, $c_4= 3.6464$, $c_5=6.5406$, $c_6=0.0048$.			
LSTM-1 input	Evaluation	1	0.0147	0.999	0.0238	0.999	0.0612	0.999	0.0682
	Paramètres	t				t			
LSTM-2 input	Evaluation	0.999	0.0105	0.999	0.0203	0.999	0.0574	0.984	0.0651
	Paramètres	t, σ				, σ			
LSTM-7 input	Evaluation	0.999	0.0164	0.998	0.0196	0.999	0.0548	0.901	0.0571
	Paramètres	t, σ , M, ROC, AC, AO, SMA				t, σ , M, ROC, AC, AO, SMA			
CNN-1 input	Evaluation	0.999	0.0167	0.999	0.0217	0.999	0.0167	0.999	0.0217
	Paramètres	t				t			
CNN-2 input	Evaluation	0.999	0.0122	0.999	0.0211	0.999	0.0122	0.996	0.0111
	Paramètres	t, σ				, σ			
CNN-7 input	Evaluation	0.999	0.0121	0.998	0.0175	0.999	0.0199	0.991	0.0105
	Paramètres	t, σ , M, ROC, AC, AO, SMA				t, σ , M, ROC, AC, AO, SMA			
MGGP-1 input	Evaluation	0.999	0.0106	0.998	0.0218	0.997	0.1185	-25.3	10.479
	Paramètres	t				t			
MGGP-2 input	Evaluation	0.999	0.0088	0.999	0.0111	0.997	0.1211	0.472	1.482
	Paramètres	t, σ				t, σ			
MGGP-7 input	Evaluation	1	2.4×10^{-5}	0.975	0.055	0.999	0.0065	0.602	0.236
	Paramètres	t, σ , M, ROC, AC, AO, SMA				t, σ , M, ROC, AC, AO, SMA			
Code élément fini ILLICON	Evaluation	0.986	0.106	0.439	0.221	0.980	0.438	0.951	0.520

4 Préviation de la pression interstitielle

Dans la première partie, il était question de prédire le tassement. Dans cette partie, il sera question de prédire la pression interstitielle. Ce sont les mêmes approches qui seront utilisées et seront appliquées aux deux sites précédemment sélectionnés, Ma12 et Ma13. La prédiction sera étudiée en considérant le même paramétrage et en faisant varier les paramètres d'entrées, la pression interstitielle (u'), le chargement (σ) et les indicateurs techniques (SMA, AC, OC, ROC et M).

4.1 Préviation de la pression interstitielle par MGGP

La prédiction de la pression interstitielle en fonction du temps sera effectuée par la même procédure que celle décrite pour le tassement (paragraphe 3.3.1). C'est l'approche essai-erreur qui a été utilisée. Celle-ci permet d'ajuster les paramètres en fonction du résultat obtenu. Dans le tableau 4.8 (du chapitre 4) sont reportés les principaux paramètres fixés dans le programme.

4.1.1 Résultats et validation du modèle

4.1.1.1 Terminal 1

a) Premier cas

D'après la figure 5.56, la moyenne fitness varie entre 30 et 40, ceci montre que l'entrée choisie pour présenter la pression interstitielle ne donne pas les résultats escomptés. De même, l'estimateur a quasiment stagné après la 20^{ème} itération, ça veut dire que les terminaux choisis par le modèle ne sont pas capables d'améliorer l'apprentissage.




Figure 5.56 Performances du modèle MGGP-1 input (Ma12).

Le meilleur individu retenu présente un coefficient de détermination R^2 de 0,636 et un RMS de 143.60. Le modèle obtenu à l'issue de cette optimisation est présenté par l'équation (5.18):

$$S(t) = 0.007458 \times t^{7/4} - 0.2414 \times \left(t^{5/2} \times \ln(t) \right)^{1/2} - 0.1458 \times (t + 15.95)^{3/2} \times t + 76.4 \quad (5.18)$$




Figure 5.57 Pression interstitielle prédite par le modèle MGGP-2 input (Ma12).

Que ce soit pour la phase d'apprentissage ou pour la phase du test, la figure 5.57 montre une forte dispersion entre la courbe mesurée et courbe prédite. Cet écart est devenu significatif après 5700 jours. Cela s'explique par le mauvais choix des gènes qui ne sont pas assez flexibles pour que le modèle puisse prédire de manière fiable les jours suivants.

b) Deuxième cas

Dans le deuxième cas qui contient la pression interstitielle mesurée et le chargement, les résultats (Figure 5.58) montrent que la précision s'est améliorée avec le nombre d'entrée, la valeur moyenne fitness a diminué de 19 %. Cela prouve, encore une fois, que le nombre de données utilisés dans le modèle a une influence directe sur la précision des résultats.




Figure 5.58 Performances du modèle MGGP-2 input (Ma12).

Le meilleur individu retenu présente un coefficient de détermination R^2 de 0,760 et un RMS de 75, 838. Le modèle obtenu à l'issue de cette optimisation est présenté par l'équation (5.19):

$$S(t, \sigma) = 4.776 \times 10^{-3} \times \left(\sigma^2 + 2 \times t^{\frac{1}{2}} \right) \left(\sigma^2 + \frac{t}{\sigma} \times t^{\frac{1}{2}} \right) + 2.439 \times (3 \times t + 4 \times \sigma)^{\frac{1}{2}} - 0.06206 \times \left(\sigma - t^{\frac{1}{2}} \right) (t + 2 \times \sigma)^{\frac{1}{2}} + 65.74 \tag{5.19}$$

Ce modèle est meilleur que le précédent et marque une amélioration considérable par rapport aux phases d'apprentissage et du test (Figure 5.59). Le niveau élevé des taux d'erreur est principalement dû à la complexité du problème étudié.




Figure 5.59 Pression interstitielle prédite par le model MGGP-2 input (Ma12).

c) Troisième cas

Après la 200^{ème} itération, la dispersion de la moyenne fitness avoisine le chiffre 10. Ceci nous permet de dire que le modèle n’a pas réussi à trouver une solution optimale (Figure 5.60).




Figure 5.60 Performances du modèle MGGP-7 input (Ma12).

Le meilleur individu retenu présente un coefficient de détermination R^2 de 0,999 et un RMS de 0,0111. Le modèle obtenu à l’issue de cette optimisation est présenté par l’équation (5.20):

$$S(t, M, SMA, AC) = 0.16 \times M + 2 \times SMA + |AC| + 1.16 \times \exp(-\sigma) + 0.16 \times \exp(-SMA) - 1.132 \times 10^{-5} \times t \times AO - 2.265 \times 10^{-5} \times M \times SMA - \frac{0.16 \times (AO + SMA)}{t} - 1.132 \times 10^{-5} \times \sigma \times M \times AO - 0.002223 \quad (5.20)$$




Figure 5.61 Pression interstitielle prédite par le modèle MGGP-7 input (Ma12).

Pour la phase d'apprentissage, les indicateurs techniques utilisés ont permis d'accroître l'efficacité du modèle, mais cette amélioration ne fournit pas de bons repères pour juger de la performance de l'estimateur. La phase du test affiche une diminution de taux d'erreur et une amélioration des résultats par apport au modèle précédent, mais la forme de la courbe prédite ne correspond plus à la forme de la courbe réelle (Figure 5.61). Une dispersion importante est observée autour de la courbe mesurée avec un nombre non négligeable des variations.

4.1.1.2 Terminal 2

a) Premier cas

Les résultats illustrés sur la figure 5.62 montrent que la courbe de convergence a été stabilisée après la 60^{ème} itération. Le modèle contenant seulement le temps a donné la plus basse précision en référence notamment à l'erreur quadratique moyenne du test. Ceci est principalement dû au nombre des données d'apprentissage.




Figure 5.62 Performances du modèle MGGP-1 input (Ma13).

Les résultats de la figure 5.63 montrent qu'une faible erreur est notée pour la phase d'apprentissage, contrairement à la phase du test, cela est dû au mauvais apprentissage.




Figure 5.63 Pression interstitielle prédite par le modèle MGGP-1 input.

Ce modèle ne présente pas la relation entre la pression interstitielle et le temps. Le coefficient R^2 montre que le modèle proposé pour la prédiction de la pression interstitielle a offert une mauvaise précision. Le meilleur individu retenu présente un RMS égal à 341.41 et un coefficient de détermination R^2 égal à 0.874. Le modèle obtenu à l'issue de cette optimisation est présenté par l'équation (5.21):

$$S(t) = 51.28 \times \cos\left(t^{\frac{1}{2}}\right) \left(\cos(\ln(t))\right)^2 + 0.4835 \times \left(\cos(\ln(t))\right)^2 \left(t - t^{\frac{1}{2}}\right) - 1.03 \times 10^{-5} \times \cos(\ln(t))(t + 17.19)^{\frac{1}{2}} (t + 17.3)(t + 18.6) - 13.88 \tag{5.21}$$

b) Deuxième cas

Des signes encourageants ont été constatés sur la phase d'apprentissage, une diminution considérable de l'erreur quadratique moyenne dès les premières itérations a été notée. Elle a été réduite à environ 47 % (Figure 5.64). Par contre, lorsque la courbe observée et comparée à la courbe prédite dans la phase de test (Figure 5.65), il apparait qu'il n'existe pas de relation entre la pression interstitielle, le temps et le chargement. Cette divergence est attribuée à la faiblesse de la base des données d'apprentissage par rapport à celle des mesures de la couche Ma12 d'un point de vue quantitatif.




Figure 5.64 Performances du modèle MGGP-2 input (Ma13).

Le meilleur individu retenu présente un coefficient de détermination R^2 de 0.552 et un RMS de 346.503. Le modèle obtenu à l'issu de cette optimisation est présenté par l'équation (5.22):

$$S(t, \sigma) = 0.01089 \times t \times \sigma^{1/2} - 9.425 \times 10^{-11} \times \sigma^5 + \frac{9.425 \times 10^{-7} \times \sigma^{\frac{7}{2}} \times (t+2\sigma)}{t} + 3.58 \tag{5.22}$$

En conclusion, on peut dire que le chargement ajouté au modèle comme un paramètre d'entrée était insuffisant pour obtenir une meilleure précision (Figure 5.65).




Figure 5.65 Pression interstitielle prédite par le modèle MGGP-2 input (Ma13).

c) *Troisième cas*

L'intégration du temps, du chargement et les indicateurs techniques au modèle ont permis une diminution importante du taux d'erreur dans la phase d'apprentissage et la phase du test.




Figure 5.66 Performances du modèle MGGP-7 input (Ma13).

La courbe fitness ne montre pas d'amélioration de la convergence avec l'augmentation du nombre des itérations, mais cette convergence est dans une gamme acceptable avec 200 itérations (Figure 5.66). Il arrive souvent qu'une courbe s'ajuste étroitement à la courbe observée mais ne fournisse pas de prévisions précises lorsqu'elle est extrapolée. Dans ce cas Le modèle a réussi, de façon très significative, à prévoir la pression interstitielle dans les phrases d'apprentissage et test (Figure 5.67), ce qui signifie le bon choix et le bon emplacement des fonctions mathématique utilisée (Equation 5.23).




Figure 5.67 Pression interstitielle prédit par le model MGGP-7 input (Ma13).

Les paramètres R^2 et R^2 ajusté montrent que le modèle proposé pour la prédiction de la pression interstitielle offre une très bonne précision. Le coefficient de détermination R^2 est de 0,798 et le RMS est de 8.820. Le modèle obtenu à l'issu de cette optimisation est présenté par l'équation (5.23):

$$S(t, M, SMA, AC, ROC) = 0.225 \times (M - AC) + 1.999 \times (SMA - \exp(-\cos(ROC))) + 0.225 \times \exp(-\exp(-M)) - 43.71 \times \exp(-SMA)(1 - \exp(AC)) + 0.7025 \quad (5.23)$$

4.2 Prévision de la pression interstitielle par l'apprentissage profond

4.2.1 Prévision de la pression interstitielle par un réseau LSTM

Après la réussite du premier essai, c'est la validité du modèle qui sera testée. Ce test fait appel à des techniques de mémoire par le biais de séries de données sur la pression interstitielle. Dans cette application, la procédure d'essai déjà utilisée précédemment sera réutilisée (paragraphe 3.4.2.1).

4.2.1.1 Résultats et validation du modèle

4.2.1.1.1 Terminal 1

a) Premier cas

Avec un seul paramètre d'entrée, le modèle offre la souplesse nécessaire pour répondre pleinement aux objectifs visés. Les résultats générés offrent une précision satisfaisante avec une erreur égale à 0.678 et un coefficient de détermination égal à 0.999 (Tableau 5.19). L'élément clé de la bonne performance du modèle reste le choix de la bonne combinaison entre le paramétrage et la topologie du réseau.

Tableau 5.19 Évaluation du modèle LSTM- 1 input (Ma12)

Modèle	R ²		MAD		RMS	
	Train	Test	Train	Test	Train	Test
LSTM- 1 input	0.999	0.999	1.0805	0.6093	2.1820	0.6780




Figure 5.68 Pression interstitielle observée et prédite par le modèle LSTM-1 input (Ma12).




Figure 5.69 Performances du modèle LSTM-1 input (Ma12).

D'après les résultats obtenus, l'écart semble augmenter graduellement avec le temps (Figure 5.68). L'écart a été relativement stable au cours de la période entre 5000 et 7000 jours. Une augmentation est notée ensuite, elle fait passer l'écart de 0.04 % en 6800 jours à 0.5 % en 7250 jours. Il semble que cette constatation est induite par la propagation des incertitudes générées sur les résultats des calculs.

b) Deuxième cas

La ressemblance des deux modèles (avec chargement et sans chargement) est claire, ce qui signifie que le chargement n'a pas apporté d'amélioration significative (Figure 5.70). En se basant sur les résultats des prédictions obtenues par ces deux modèles, le LSTM a montré une excellente capacité prédictive avec une légère différence dans la précision. Les courbes de prédiction avec et sans chargement étaient identiques dans une large mesure avec ceux mesurés. Finalement, les

résultats des tests de validation confirment que la modélisation par cette approche se distingue par sa haute capacité prédictive et une bonne précision (Tableau 5.20).

Tableau 5.20 Évaluation du modèle LSTM- 2 input (Ma12)

Modèle	R ²		MAE		RMS	
	Train	Test	Train	Test	Train	Test
LSTM- 2 input	0.999	0.999	1.9117	0.9064	2.5972	1.0094




Figure 5.70 Pression interstitielle observée et prédite par le modèle LSTM- 2 input (Ma12).




Figure 5.71 Performances du modèle LSTM- 2 input (Ma12).

c) Troisième cas

Les indicateurs techniques ont rendu l'apprentissage facile et flexible avec une hausse de 15% par rapport à celle obtenue par le modèle précédent (Tableau 5.21).

Tableau 5.21 Évaluation du modèle LSTM- 7 input (Ma12)

Modèle	R ²		MAE		MSE	
	Train	Test	Train	Test	Train	Test
LSTM- 7 input	0.999	0.998	1.3985	1.0019	1.8389	1.2363

D'après la figure 5.72, le modèle LSTM a réussi pour la première fois à établir une relation entre les indicateurs techniques, la pression interstitielle au temps présent et dans le futur. Les résultats obtenus montrent que le modèle proposé peut prédire la pression interstitielle pour les différents intervalles du temps.




Figure 5.72 Pression interstitielle observée et prédite par le modèle LSTM- 7 input (Ma12).




Figure 5.73 Performances du modèle LSTM-7 input (Ma12).

4.2.1.1.2 Terminal 2

a) Premier cas

Le modèle ne dispose pas d'informations quantitatives pour l'apprentissage, pourtant la courbe de validation ressemble à une droite aux alentours du zéro (figure 5.75). Ceci prouve encore une autre fois que l'approche utilisée a une capacité de comprendre et d'utiliser correctement les informations. Cette étude corrélationnelle fondée sur un seul paramètre d'entrée a démontré une bonne performance avec un coefficient de détermination proche de l'unité et une erreur quadratique moyenne de 1.7810 (Tableau 5.22).

Tableau 5.22 Évaluation du modèle LSTM- 1 input (Ma13)

Modèle	R ²		MAD		RMS	
	Train	Test	Train	Test	Train	Test
LSTM- 1 input	0.998	0.999	2.6413	1.6965	4.1690	1.7810

Sur la figure, on note que l'écart entre la courbe prédite et la courbe mesurée augmente à une vitesse de 2 cm /jour. Ce qui signifie que l'utilisation du modèle à long terme (plus de 4000 jours) risque de diminuer la précision du modèle (Figure 5.75).




Figure 5.74 Pression interstitielle observé et prédit par le modèle LSTM- 1 input (Ma13).




Figure 5.75 Performances du modèle LSTM- 1 input (Ma13).

b) Deuxième cas

Contrairement à ce que nous avons observé au cours des simulations antérieures, la croissance du nombre d'entrée s'accompagnait d'une amélioration de la performance lors de la phase d'apprentissage. Nous remarquons ici un fort écart entre la courbe prédite et la courbe mesurée (Figure 5.76). La conclusion que l'on tire de cette expérience est que le chargement n'a pas aidé substantiellement dans l'opération de filtre des informations contenues dans les cellules, par conséquent, la décision devient difficile.

La précision du modèle proposé a été vérifiée en utilisant des données réelles du terrain et les résultats ont été moins satisfaisants par rapport à la simulation précédente (Tableau 5.23).

Tableau 5.23 Évaluation du model LSTM- 2 input appliquer sur la couche Ma13

Modèle	R ²		MAD		RMS	
	Train	Test	Train	Test	Train	Test
LSTM- 2 input	0.995	0.993	4.1381	4.1742	5.3544	4.8989




Figure 5.76 Pression interstitielle observée et prédite par le modèle LSTM- 2 input (Ma13).




Figure 5.77 Performances du modèle LSTM- 2 input (Ma13).

c) *Troisième cas*

L'utilisation des indicateurs techniques a engendré une amélioration notable du résultat par apport au modèle précédent (Tableau 5.24). Le nombre de données qui a été employé pour le développement de ce modèle n'est pas significatif en termes de quantité (1096 jours), ce qui augmente le risque de ne pas pouvoir apprendre assez précisément, et donc de faire des mauvaises prédictions à long terme.

Tableau 5.24 Évaluation du model LSTM- 7 input (Ma13)

Modèle	R ²		MAE		RMS	
	Train	Test	Train	Test	Train	Test
LSTM- 7 input	0.997	0.971	2.7763	2.8814	4.1490	3.4134

Lorsqu'on compare la courbe prédite et celle simulée, on note qu'il existe quelques points qui sont dispersés. Ces points ont une grande influence sur la précision du modèle. Concernant la forme de la courbe, on constate que l'allure est différente (Figure 5.78). Alors, ce modèle n'est pas le meilleur pour représenter cette relation.




Figure 5.78 Pression interstitielle observée et prédite par le model LSTM- 7 input (Ma13).




Figure 5.79 Performances du modèle LSTM- 7 input (Ma13).

4.2.2 Pr evision de la pression interstitielle par un r eseau CNN

Cette partie sera consacr ee   l' tude de la pression interstitielle par un r eseau de neurones convolutifs. De la m eme mani ere que dans le cas des tassements, nous avons suivi la proc edure d efinies dans le paragraphe 3.4.3.1. Notons que la topologie du mod ele garde le m eme empilage multicouche.

4.2.2.1 R esultats et validations du mod ele

4.2.2.1.1 Terminal 1

a) Premier cas

Le mod ele permet le traitement des diff erentes  tapes de pr ediction avec un seul param etre d'entr ee. Selon le tableau 5.25, les r esultats g en er es offre une mauvaise pr ecision avec une erreur  gale   11.546 et un coefficient de d etermination de 0.999.

Tableau 5.25  valuation du mod ele CNN- 1 input (Ma12)

Mod�ele	R ²		MAD		RMS	
	Train	Test	Train	Test	Train	Test
CNN- 1 input	0.999	0.999	2.0215	8.4743	3.7300	11.5460

Nous remarquons aussi que la forme de la courbe de la pression g en er ee n'a pas la m eme allure que celle mesur ee (Figure 5.80). Cela veut dire que les couches de convolution utilis ees ne sont pas capables de d etecter toutes les informations pertinentes dans les vecteurs d'entr es.




Figure 5.80 Pression interstitielle observ ee et pr edite par le mod ele CNN- 1 input (Ma12).




Figure 5.81 Performances du mod ele CNN-1input (Ma12).

b) Deuxi eme cas

Avec deux param etres, la phase d'apprentissage enregistre une am elioration, elle est de l'ordre de 53% par rapport au cas o u seul un param etre d'entr ee a  t e utilis e (Tableau 5.26). Cette am elioration ne garantit pas que le mod ele fonctionne correctement dans une plage de mesure plus large jusqu'  7300 jours.

Tableau 5.26  valuation du model CNN- 2 input (Ma12).

Mod�ele	R ²		MAE		RMS	
	Train	Test	Train	Test	Train	Test
CNN- 2 input	0.999	0.999	2.7787	4.4444	3.9538	5.3418

La phase de test a fourni une faible capacit e pr edictive   cause notamment des donn ees qui comportent un nombre insuffisant d'entr ees et qui int egrent des entr ees qui n'ont pas v eritablement

un lien avec la variable cible. Cependant, le modèle a réussi parfaitement à suivre le même sens du mouvement et admet une erreur assez faible sur les intervalles [3500 - 6000] et [6100 - 6900] (figure 5.82).




Figure 5.82 Pression interstitielle observée et prédite par le modèle CNN- 2 input (Ma12).




Figure 5.83 Performances du modèle CNN- 2 input (Ma12).

c) Troisième cas

Il faut souligner que le choix d'un nombre suffisant de bons prédicteurs est d'une importance capitale pour la modélisation prédictive. L'utilisation des indicateurs techniques qui disposent d'informations précises sur la pression interstitielle ont apporté une remarquable amélioration dans la phase d'apprentissage (Tableau 5.27). D'après la figure 5.84, le modèle a passé avec succès la phase du test. Cela signifie que l'ajout d'information supplémentaire a permis au modèle de trouver une liaison entre les variables d'entrée et les variables de la cible malgré sa complexité.

Tableau 5.27 Évaluation du modèle CNN- 7 input (Ma12)

Modèle	R ²		MAD		RMS	
	Train	Test	Train	Test	Train	Test
CNN- 7 input	0.999	0.998	1.7246	2.7689	2.9115	3.5026

Les paramètres SMA, AC, OC, ROC et M intégrés au réseau ont contribué à une réduction de 34.5% de l'erreur quadratique moyenne par rapport au modèle à deux paramètres d'entrée.




Figure 5.84 Pression interstitielle observée et prédite par modèle CNN- 7 input (Ma12).




Figure 5.85 Performances du modèle CNN- 7 input (Ma12).

4.2.2.1.2 Terminal 2

a) Premier cas

Pour la phase du test, la figure 5.86 montre un écart important entre la courbe prédite et la courbe mesurée. Cet écart provient généralement d'une mauvaise compréhension ou caractérisation du phénomène. On note également que la courbe prédite ne suit pas une trajectoire régulière. Ce qui peut conduire à augmenter le pourcentage d'erreur en fonction du temps. Même si le modèle ne dispose pas d'un nombre des données suffisant pour l'apprentissage, il a pu générer des résultats relativement stables durant la phase d'apprentissage avec une erreur absolue moyenne égale à 6.349 et un coefficient de détermination qui vaut 0.998 (Tableau 5.28).

Tableau 5.28 Évaluation du modèle CNN- 1 input (Ma13)

Modèle	R ²		MAD		RMS	
	Train	Test	Train	Test	Train	Test
CNN- 1 input	0.998	0.999	4.1654	9.1105	6.3490	15.4160




Figure 5.86 Pression interstitielle observée et prédite par le modèle CNN- 1 input (Ma13).




Figure 5.87 Performances du modèle CNN- 1 input (Ma13).

b) Deuxième cas

L'ajout du chargement a engendré une nette diminution de l'erreur absolue moyenne. Une augmentation de coefficient de détermination est constatée aussi. Cette amélioration est due à la bonne caractérisation de la pression interstitielle (Tableau 5.29). Ceci concorde avec les différents travaux qui ont démontré que l'utilisation d'un nombre suffisant de paramètres procurent au modèle une meilleure flexibilité et augmente sa capacité prédictive (Mohammadi Bayazidi et al., 2014; Bourouis et al., 2016).

Tableau 5.29 Évaluation du modèle CNN- 2 input (Ma13)

Modèle	R ²		MAD		RMS	
	Train	Test	Train	Test	Train	Test
CNN- 2 input	0.995	0.993	4.5533	3.5438	5.6639	4.4840

Pour la phase du test (figure 5.88), l'augmentation du nombre d'entrée s'accompagnait d'une amélioration significative par rapport à la simulation précédente. Le fait que le modèle développé ne génère pas une courbe qui suit correctement l'allure de la courbe mesurée, il n'est pas considéré comme représentatif de cette relation.




Figure 5.88 La pression interstitielle observé et prédit par le model CNN- 2 input (Ma13).




Figure 5.89 Les performances du model CNN- 2 input (Ma13).

c) Troisième cas

Dans la même logique, nous avons procédé à la modélisation des mêmes données que celles adoptées pour les simulations précédentes. Nous remarquons sur la figure 5.90 une grande concordance entre les résultats de prédiction et les valeurs mesurées. Ceci est confirmé par les critères d'évaluation statistique notamment le coefficient de détermination qui vaut 0,971 et par l'erreur absolue moyenne qui est égale à 5,360. Le modèle a démontré sa capacité à générer des résultats même dans un environnement difficile.




Figure 5.90 La pression interstitielle observé et prédit par le model CNN- 7 input (Ma13).




Figure 5.91 Les performances du model CNN- 7 input (Ma13).

Le modèle développé présente des résultats satisfaisants pour les deux phases, apprentissage et test (Tableau 5.30). Cela signifie que l'intégration des indicateurs techniques au modèle a fourni des informations supplémentaires au réseau, ce qui a permis d'obtenir des résultats meilleurs en termes d'efficacité.

Tableau 5.30 Évaluation du modèle CNN- 7 input (Ma13)

Modèle	R ²		MAD		RMS	
	Train	Test	Train	Test	Train	Test
CNN- 7 input	0.997	0.971	4.0653	3.0993	5.3601	3.2231

4.3 La comparaison entre les approches développées MGGP, LSTM et CNN

Le tableau de la page suivante (tableau 5.31) présente les résultats des évaluations des prédictions des différents modèles utilisés ici (MGGP, LSTM, CNN) et du code éléments finis ILLICON par rapport aux données expérimentales. Les figures 5.61 et 5.67 montrent que les phases d'apprentissage des modèles MGGP sont nettement améliorées par les indicateurs techniques. Ces indicateurs ont facilité la caractérisation de la pression interstitielle et la convergence rapide vers une solution optimale. Cependant, un bon entraînement ne signifie pas forcément les mêmes performances seront conservées à long terme. La phase de test a présenté une erreur prévisionnelle plus importante et un biais négatif (figures 5.61 et 5.67). Pour une erreur inférieure à 10%, le modèle MGGP a réussi de prédire seulement les 20 premiers jours pour le terrain Ma12 et les 40 premiers jours pour le terrain Ma13. Ce rapport risque d'être augmenté par les erreurs cumulées en fonction du temps. En conclusion et sur la base de ces résultats, on peut avancer le fait que le MGGP ne peut pas être retenu comme modèle prédictif de la pression interstitielle. Pour les problèmes complexes qui comportent des données bruitées, l'apprentissage trouvera des difficultés pour converger vers une solution optimale. Dans notre cas, le problème est relativement facile puisque le comportement est contrôlé par les caractéristiques physiques, hydriques et mécaniques du sol. En se basant sur l'erreur absolue moyenne (RMS) et le coefficient de détermination, les modèles issus de LSTM présente de meilleures performances que ceux des CNN, MGGP et ILLICON. Malgré le peu de données disponibles pour l'entraînement, les prédictions par le réseau CNN sont relativement satisfaisantes durant une période de 24 mois. Cependant, le modèle perd sa crédibilité en dépassant le 25^{ème} mois. Les performances peuvent être améliorées par l'utilisation d'un nombre important de données d'entraînement pour que le réseau puisse traiter le problème et améliorer la qualité de la prédiction.

Tableau 5.31 Comparaison entre les approches développées et les méthodes existantes

Modèles		Ma12				Ma13			
		Train		Test		Train		Test	
		R ²	RMS	R ²	RMS	R ²	RMS	R ²	RMS
MGGP-1 input	Evaluation	0.880	25.224	0.6363	143.64	0.8642	26.957	0.8741	341.41
	Paramètres	t				t			
MGGP-2 input	Evaluation	0.948	16.689	0.7602	75.838	0.914	21.421	0.552	346.50
	Paramètres	t, σ				t, σ			
MGGP-7 input	Evaluation	0.999	0.2222	0.2941	38.948	0.999	0.6033	0.798	8.8990
	Paramètres	t, σ , M, ROC, AC, AO, SMA				t, σ , M, ROC, AC, AO, SMA			
LSTM -1 input	Evaluation	0.999	2.1820	0.999	1.6780	0.998	4.1690	0.999	1.7810
	Paramètres	t				T			
LSTM -2 input	Evaluation	0.999	2.5978	0.999	1.0094	0.995	5.3544	0.993	4.8989
	Paramètres	t, σ				t, σ			
LSTM -7 input	Evaluation	0.999	1.8389	0.998	1.2363	0.997	4.1490	0.971	3.4134
	Paramètres	t, σ , M, ROC, AC, AO, SMA				t, σ , M, ROC, AC, AO, SMA			
CNN-1 input	Evaluation	0.999	3.7300	0.999	11.546	0.998	6.3490	0.999	15.416
	Paramètres	t				t			
CNN- 2 input	Evaluation	0.999	3.9538	0.999	5.3418	0.995	5.6639	0.993	4.4840
	Paramètres	t, σ				t, σ			
CNN-7 input	Evaluation	0.999	2.9115	0.998	3.5026	0.997	5.3601	0.971	3.2231
	Paramètres	t, σ , M, ROC, AC, AO, SMA				t, σ , M, ROC, AC, AO, SMA			
Code élément fini ILLICON	Evaluation	0.127	152.102	0.741	202.17	0.0769	110.49	0.848	48.250

5 Conclusion

L'objectif de cette étude est d'établir des modèles capables de prédire la pression interstitielle et le tassement à long terme avec une précision acceptable et s'adapte rapidement et de manière adéquate à un comportement complexe du sol. Pour le tassement, la méthode d'Asaoka (1978) est la méthode la plus utilisée en pratique car elle est simple d'utilisation et peut être mis en œuvre rapidement. Cependant, nous pensons que cette méthode ne présente pas correctement le tassement réel. Il est probable, comme le souligne Magnan et Deroy (1980), que le choix du pas de temps rend difficile son utilisation dans la pratique. L'utilisation des modèles MTM-AG et MTM-PSO a donné de meilleurs résultats. La combinaison entre les fonctions mathématiques a conduit à une amélioration significative de la précision à courte terme. Le processus apporte des avantages multiples, la simplicité d'implémentation, un temps de calcul très court et une gestion de l'environnement peu coûteuse, ce qui peut aider les ingénieurs à prendre les décisions adaptées dans des situations critiques. La division de la base de données selon les saisons météorologiques a aidé le modèle LSTM de reproduire le phénomène, les résultats montrent qu'il s'adapte efficacement au changement du comportement. Les résultats obtenus par LSTM et CNN montrent clairement que nous avons réussi à tirer la meilleure architecture du réseau. Les courbes générées par ces deux approches indiquent qu'il est possible de reproduire d'une manière très proche les courbes observées en fonction du temps. Nous avons montré qu'après un faible apprentissage, les données prédisent le comportement du terrain avec un minimum d'erreur. L'utilisation des couches de convolution pour CNN est très intéressante pour leur souplesse d'une part et pour leurs caractéristiques optimales du phénomène d'autre part.

Par rapport la prévision de la pression interstitielle, la plus plupart des équations générés par le MGGP, ont une forme parabolique qui est généralement utile pour des données qui changent de direction au fil du temps, soit en augmentant puis en diminuant, ou vice versa. Néanmoins, le modèle a échoué de prédire convenablement les valeurs future de la pression interstitielle. Ce résultat s'explique par le fait que les données utilisé suivent une tendance complexe et présentent de forts cycles saisonniers. D'après les résultats obtenus, le model MGGP il convient particulièrement aux séries chronologiques qui suivent une tendance prévisible et ne présentant pas de forte pics. Souvent, une seule couche LSTM ne suffit pas à capter toute l'information contenue dans les séquences. L'empilement de 3 couches a permet d'extraire des informations plus complexes à partir des entrées, et ainsi d'avoir une meilleure modélisation de nos données.

D'une manière générale, un réseau de neurone profond donne des bons résultats. Les résultats obtenus se sont améliorés à mesure que nous avons approfondie notre réseau et augmenté le nombre d'entrée. La base d'apprentissage est également un élément déterminant dans les réseaux de neurones convolutionnels, il faut avoir une base d'apprentissage de grande taille pour aboutir à des meilleurs résultats.

CONCLUSION GENERALE

Les sols fins argileux ont la particularité de produire un tassement qui peut être divisé en deux phases, un tassement primaire et un tassement secondaire. Le premier est plus ou moins rapide et est dû à l'expulsion de l'eau contenu dans les vides du sol. Le second est beaucoup plus lent, il est dû à la déformation des particules solides et met plusieurs années pour se stabiliser. La contrainte de préconsolidation (σ'_p) ainsi que les indices de gonflement (C_s), de compression primaire (C_c) et de compression secondaire (C_a) sont les paramètres les plus couramment utilisés pour prévoir le tassement à long terme. Ces paramètres, qui sont des paramètres clés pour la plupart des modèles de comportement viscoplastique applicables dans la pratique des ingénieurs (Graham, 1989), sont généralement obtenus par des essais œdométriques conventionnels. La durée importante des essais œdométriques conduit à utiliser, chaque fois que c'est possible, des corrélations avec des paramètres de détermination plus rapide, comme la teneur en eau, l'indice de vide et les limites d'Atterberg pour compléter la caractérisation des sols compressibles sur les sites de projets de grande ampleur. Notre étude s'inscrit dans ce contexte général. L'objectif de la recherche était de développer un modèle prédictif intelligent qui repose sur l'exploitation d'une base de données contenant des paramètres géotechniques facilement mesurables et basé sur l'intelligence artificielle. Quatre modèles de prédiction ont été mis à l'épreuve dans cette thèse, les réseaux neurones artificiels (RNN), une méthode basée sur l'hybridation d'abord entre les réseaux neurones artificiels et les algorithmes d'optimisation, ensuite entre les algorithmes génétiques et les essais particuliers. Les principales conclusions tirées de cette étude sont :

❖ La stratégie du prétraitement utilisée a joué un rôle important dans l'amélioration de la qualité des modèles prédictifs. Notre stratégie a comporté deux étapes fondamentales, la première a consisté en l'élimination des valeurs aberrantes qui se situent très loin des autres valeurs de l'ensemble de données et la deuxième étape a consisté en la normalisation des données par une fonction Min-Max qui conserve la distribution des valeurs originales à un facteur d'échelle près et transforme les valeurs dans l'intervalle [-1, 1]. Le traitement de la première phase a été effectué à partir de la primitive conditionnel «if» en utilisant la MGGP. Avec cette primitive, le système cherche le critère le plus déterminant et découpe la population en sous populations possédant la même entité de ce critère. Ce qui nous a facilités la définition du domaine d'application des deux modèles développés.

❖ L'hybridation entre deux approches métas-heuristiques, les réseaux de neurones et les essais particuliers, a permis d'obtenir des résultats de prédiction satisfaisants pour trois paramètres. L'erreur relative sur la prédiction est inférieure à 10%, ce qui constitue un résultat encourageant. Le choix du nombre de couches cachées, le nombre de neurones cachés et le nombre d'itérations constitue un élément clé pour le bon fonctionnement du réseau. Dans notre étude, la combinaison qui a donné satisfaction est constituée de deux couches cachées et 150 itérations.

❖ La fonction d'activation d'une unité neuronale peut accepter des valeurs d'entrée de n'importe quel ordre de grandeur et produira des sorties dans un intervalle strictement limité. Pour une fonction sigmoïde, si les valeurs d'entrées sont situées en dehors de l'intervalle $[0, +1]$, le neurone perd l'information à cause d'une saturation. Cet effet va sévèrement limiter la possibilité du réseau à détecter la relation entrée-sortie. Cela signifie que l'ordre de positionnement de ses fonctions peut profondément influencer sur la performance du réseau de neurones. Les résultats de NN-PSO ont montré que nos choix de positionnement, de la fonction tangente hyperbolique dans la première couche cachée et de la fonction linéaire saturée dans la deuxième couche cachée, ont été judicieux et ont permis d'éviter ce phénomène.

❖ L'optimisation par essaim particulier utilise la diversification pour une recherche efficace et elle s'applique facilement aux problèmes de plusieurs dimensions avec une convergence très rapide.

❖ Les résultats obtenus par la MGGP sont très satisfaisants, en se référant à la bonne concordance entre les résultats prédits et les mesures expérimentales. La MGGP est donc, à notre sens, la mieux adaptée au problème puisqu'elle possède aussi un temps d'apprentissage plus court.

❖ La technique NN-PSO génère des erreurs plus élevée, les résultats sont donc moins bons que ceux fournis par la MGGP. Ceci signifie que l'utilisation des paramètres ayant une faible corrélation est beaucoup pénalisant et qu'à partir d'un faible nombre d'entrées, le problème devient trop complexe. Par contre, elle présente de très bonnes propriétés de convergence au voisinage du minimum, ce qui peut s'avérer rapide en termes de temps du calcul.

❖ Les sols ont un comportement qui dépend de la variabilité spatiale des paramètres, il serait donc préférable d'augmenter le nombre des paramètres influents sur les modèles de prédiction, ce qui rendra l'apprentissage plus correct et améliore la qualité des prédictions.

Le travail a traité de aussi de l'identification des paramètres des modèles constitutifs de sols par analyse inverse. Afin d'avoir une méthode d'identification adaptable à tout type de mesures (ouvrages instrumentés), une méthode de résolution du problème inverse a été développée. Des valeurs a priori sont données aux paramètres inconnus pour simuler le problème direct associé, à

l'aide du code de calcul par éléments finis, jusqu'à ce que l'écart entre le résultat du calcul numérique et les données expérimentales soit minimal. La méthode d'identification développée dans cette thèse donne accès à une gamme de variation caractéristique de chaque paramètre. Ce travail a donc été commencé par une étude paramétrique qui permet de mieux comprendre l'impact individuel de chacun des paramètres du modèle SSCM sur le tassement. Les résultats montrent que les sept paramètres (μ^* , λ^* , κ^* , c , φ , k_h et k_v) adopté pour cette étude permettent d'ajuster d'une manière très flexible la courbe obtenue avec les résultats expérimentaux.

Nous avons conclu par cette étude que le choix adéquat des paramètres de l'algorithme et le domaine de recherche résulte d'un compromis entre la fiabilité et la qualité d'une part et le coût de calcul d'autre part. L'étude a montré également que l'effet du tassement secondaire sur l'ajustement est relié à l'effet de l'indice du fluage modifié (μ^*). L'efficacité des algorithmes génétiques (AG) dépend fortement des fonctions d'évaluation des individus ou des solutions proposées, qui sont des modèles utilisés en guise de fonctions-objectifs comme le signale (Park, 2013). Ainsi le choix des fonctions-objectifs sera d'une importance capitale.

Pour valoriser encore les résultats de ce travail, des comparaisons ont été effectuées entre les résultats des modèles simulés, les valeurs mesurées et les prédictions de quelques modèles empiriques disponibles. Ainsi, la méthode d'Asoaka n'a pas mis clairement en évidence le fluage et a fourni une valeur du tassement loin de la valeur mesuré. Le modèle hyperbolique a donné de meilleurs résultats quand il a été optimisé par l'essai particulaire. Optimisé par l'algorithme génétique, l'estimation du tassement a été influencée par la mauvaise détermination du point d'inflexion de la courbe. Globalement, les modèles basés sur les formules mathématiques se sont révélés meilleures que les méthodes empiriques mais n'ont pas mis nettement en évidence la phase de fluage, phénomène qui a été mieux représenté par le modèle multi-terme (MTM) qu'il soit optimisé par l'algorithme génétique ou par l'essai particulaire.

Finalement, nous pouvons dire que globalement, les modèles empiriques pour prédire le fluage des sols argileux sont simples d'utilisation mais fournissent des résultats souvent écartés de la réalité. Leurs combinaisons avec les techniques d'apprentissage améliorent considérablement leurs performances. L'utilisation des techniques d'optimisation dans le cadre de l'analyse du problème inverse fournit des résultats très encourageant moyennant la disponibilité des données. Enfin, l'hybridation entre les techniques d'apprentissage permet en quelque sorte de tirer profit des avantages fournis par chaque technique.

PERSPECTIVES

Quand un ensemble de terminaux est insuffisant pour exprimer une solution, la programmation génétique se limite à donner des résultats approximatifs. L'utilisation d'un nombre suffisant de terminaux ne permet pas forcément d'améliorer les performances. En fait, ça se traduit généralement par l'augmentation du temps de calcul et par l'introduction de biais imprévu. Pour pallier à ce problème, nous pensons qu'il serait bénéfique de tester d'autres méthodes pour le groupement des terminaux et la normalisation de leurs poids. Nous pensons par exemple à la logique floue (Zadeh, 1965), l'application d'un système d'inférence floue aux premières générations de la boucle évolutionnaire avec la valeur du poids des terminaux comme variable, ceci pourrait permettre une séparation rapide et efficace des variables non pertinents.

Un problème très connu en MGGP est l'accroissement incontrôlé de la taille des individus, souvent dû au croisement, qui conduit à un effet qu'on nomme effet de congestion (bloat). Ce phénomène provoque l'envahissement de l'espace mémoire du PC sur lequel tourne la simulation et peut entraîner le blocage du processus. De nombreuses solutions ont été proposées afin de limiter les conséquences de cet effet. Nous pouvons citer la fonction de génération automatique proposée par Koza (1992) et utilisée dans ce travail. Cette fonction encapsule des groupes d'individus afin de les protéger lors du croisement. Il serait intéressant de tester d'autres types d'opérateurs de croisement comme le « fair crossover » ou le « homologous crossover ». Ces opérateurs permettent de réduire le « bloat » sans contraindre la recherche de façon trop radicale et visent à garder les bons individus (systématiquement les deux meilleurs parmi les deux parents et les deux enfants).

RÉFÉRENCES BIBLIOGRAPHIQUES

- Aalto, A., Rekonen, R., Lojander, M. (1998). "The calculations on Haarajoki test embankment with the finite element program Plaxis 6.31 ". *Application of Numerical Methods to Geotechnical Problems*, Springer, Vienna, pp. 37-46. doi: 10.1007/978-3-7091-2512-0_3.
- Abbasi, N., Javadi, A., Bahramloo, R. (2012). " Prediction of compression behavior of normally consolidated fine grained soils." *World Applied Science Journal*, **18(1)**: 6-14. doi: 10.5829/idosi.wasj.2012.18.01.2675.
- Adachi, T., Oka, F. (1982). "Constitutive equations for normally consolidated clay based on elasto-viscoplasticity." *Soils and foundations*, **22(4)**: 57-70. doi: 10.3208/sandf1972.22.4_57.
- Ahadian, J., Ebnjalal R , SHAFAEI, B. M. (2008). "Determination of Soil Compression Index, Cc, in Ahwaz region." *Journal of the Faculty of Engineering*, **35(3)**: 75-80.
- Ahadiyan, J., Ebne, J., Bajestan, M. (2008). "Prediction determination of soil compression index Cc Ahwaz region." *Journal of the Faculty of Engineering* **35(3)**: 75-80.
- Alavi, A. H., Gandomi, A. H. (2011). "A robust data mining approach for formulation of geotechnical engineering systems." *Engineering Computations: Int J for Computer-Aided Engineering*, **28(3)**: 242-274.
- Alhusein, M. (2001). "Etude du comportement différe des sols et ouvrages géotechniques". Doctoral thesis, *Université Joseph Fourier*, 23 Octobre 2001 Grenoble, France, pp. 260.
- Ali, F. H., Mohamadi, R. (1989)."Critical state parametric study on control embankment." International Symposium on Trial Embankments on Malaysian Marine Clays, kuala lumpur, Malaysia, pp. 1-30.
- Al-Khafaji, A., Andersland, O. (1992). "Equations for compression index approximation." *Journal of Geotechnical Engineering*, **118(1)**: 148-153. doi: 10.1061/(ASCE)0733-9410(1992)118:1(148).
- Al-Shamrani, M. A. (1998). "Application of the C α /C c concept to secondary compression of sabkha soils." *Canadian Geotechnical Journal*, **35(1)**: 15-26. doi: 10.1139/t97-053.
- Al-Shamrani, M. A. (2004). "Applicability of the rectangular hyperbolic method to settlement predictions of sabkha soils." *Geotechnical and Geological Engineering*, **22(4)**: 563-587. doi: 10.1023/B:GEGE.0000047046.73649.04.
- Al-Taie, A., Al- Ameri, A. F. (2011). "Estimation of relationship between coefficient of consolidation and liquid limit of middle and south Iraqi soils." *Journal of Engineering*, **17(3)**: 430-440.
- Anagnostopoulos, C. A., Grammatikopoulos, I. N. (2011). "A new model for the prediction of secondary compression index of soft compressible soils." *Bulletin of Engineering Geology and the Environment*, **70(3)**: 423-427. doi: 10.1007/s10064-010-0323-x.
- Anandarajah, A., Agarwal, D. (1991). "Computer aided calibration of a soil plasticity model." *International Journal for Numerical and Analytical Methods in Geomechanics*, **15(12)**: 835-856. doi: 10.1002/nag.1610151202.
- Arabet, L. (2011)."Modelisation numerique du tassement et de la consolidation des sols sous l'oedometre." 14th

- Pan American conference on soil mechanics and geotechnical engineering, 2-6 October 2011, Toronto, Canada, pp. 1-8.
- Armaghani, D. J., Raja, N. S. B., Faizi, K., Rashid, A. S. A. (2017). "Developing a hybrid PSO–ANN model for estimating the ultimate bearing capacity of rock-socketed piles." *Neural Computing and Applications*, **28(2)**: 391-405. doi: 10.1007/s00521-015-2072-z.
- Aruga, K. (2005). "Tabu search optimization of horizontal and vertical alignments of forest roads." *Journal of Forest Research*, **10(4)**: 275-284. doi: 10.1007/s10310-004-0136-5.
- Asaoka, A. (1978). "Observational procedure of settlement prediction." *Soils And Foundations*, **18(4)**: 87-101. doi: 10.3208/sandf1972.18.4_87.
- Azzouz, A. S., Krizek, R. J., Corotis, R. B. (1976). "Regression analysis of soil compressibility." *Soils and foundations*, **16(2)**: 19-29. doi: 10.3208/sandf1972.16.2_19.
- Baguelin, F. (1999). "La détermination des tassements finaux de consolidation: une alternative à la méthode d'Asaoka ", Revue Française de Géotechnique N° 86, pp. 9-17. doi:10.1051/geotech/1999086009.
- Bartholomeeusen, G. (2003). "Compound shock waves and creep behaviour in sediment beds". Doctoral thesis *University of Oxford*, 05 April 2003, London, England, pp. 229.
- Bhattacharya, A., Basack, S. (2011). "A review of the use of the preloading technique and vertical drains for soils consolidation." Proceedings of indian geotechnical conference, 15-17 December 2011, Kochi, Kerala, India, pp. 361-364.
- Biot, M. A. (1941). "General theory of three dimensional consolidation." *Journal of Applied Physics*, **12(2)**: 155-164. doi: 10.1063/1.1712886.
- Birbil, Ş. İ., Fang, S. C. (2003). "An electromagnetism like mechanism for global optimization." *Journal of Global Optimization*, **25(3)**: 263-282. doi: 10.1023/A:1022452626305.
- Bjerrum, L. (1967). "Engineering geology of Norwegian normally consolidated marine clays as related to settlements of buildings." *Geotechnique*, **17(2)**: 83-118. doi: 10.1680/geot.1967.17.2.83.
- Borja, R., Hsieh, H., Kavazanjian, J. E. (1990). "Double-yield-surface model : Implementation and verification." *Journal of geotechnical engineering*, **116(9)**: 1402-1421. doi: 10.1061/(ASCE)0733-9410(1990)116:9(1402).
- Borja, R., Kavazanjian, J. E. (1985). "A constitutive model for the stress–strain–time behaviour of 'wet' clays." *Geotechnique*, **35(3)**: 283-298. doi: 10.1680/geot.1985.35.3.283.
- Bourouis, M. A., Zadjou, A., Djedid, A. (2016). "Neuro-genetic approach for immersed CBR index prediction". *Proceedings of the first Southern African geotechnical conference*, CRC Press, pp. 143-148. doi: 10.1201/b21335-27.
- Bourouis, M. A., Zadjou, A., Djedid, A. (2019). "Prediction of the CBR index with the multi-gene genetic programming method." Proceedings of the 17th african regional conference on soil mechanics and geotechnical engineering., 7-9 October 2019, Cape Town, South Africa, pp. 533-538.
- Brand, E. W., Brenner, R. P. (1981). "Soft clay engineering", Elsevier, 20, pp.
- Brandenberg, S. J. (2016). "iConsol. js: JavaScript implicit finite-difference code for nonlinear consolidation and

- secondary compression." *International Journal of Geomechanics*, **17(6)**: 49-61. doi: 10.1061/(ASCE)GM.1943-5622.0000843.
- Brugger, P. J., Soares de Almeida, M. d. S., Sandroni, S. S., Lacerda, W. A. (1998). "Numerical analysis of the breakwater construction of Sergipe Harbour, Brazil." *Canadian Geotechnical Journal*, **35(6)**: 1018-1031. doi: 10.1139/t98-063.
- Bui, D. T., Nhu, V. H., Hoang, N. D. (2018). "Prediction of soil compression coefficient for urban housing project using novel integration machine learning approach of swarm intelligence and multi-layer perceptron neural network." *Advanced Engineering Informatics*, **38(1)**: 593-604. doi: 10.1016/j.aei.2018.09.005.
- Buisman, A. S. K. (1936). "Results of long duration settlements tests." Proceedings of the 1st international conference on soil mechanics and foundation engineering, 22-26 juin 1936, Cambridge, USA, pp. 103-106. doi: 10.1007/BF02810267.
- Carrier, N. D. (1985). "Consolidation parameters derived from index tests." *Geotechnique*, **35(2)**: 211-213. doi: 10.1680/geot.1985.35.2.211.
- Casagrande, A. (1936). "The determination of pre-consolidation load and its practical significance." Proceedings of the 1st international conference on soil mechanics, 22-26 June 1936, Boston, USA, pp. 60-67.
- Changming, W., Qing, W., Shuhua, Z. (2004). "Creep characteristics and creep model of marine soft soils." *Chinese Journal of Rock Mechanics and Engineering*, **23(2)**: 227-230.
- Chen, W. W., Shen, Z. P., Wang, J. A., Tsai, F. (2015). "Scripting STABL with pso for analysis of slope stability." *Neurocomputing*, **148(1)**: 167-174. doi: 10.1016/j.neucom.2012.10.048.
- Choi, Y. K. (1982). "Consolidation behavior of natural clays". Doctoral Thesis Doctoral Thesis, *University of Illinois at Urbana-Champaign*, 15 Sptember 1982, Illinois. Crawford, pp.
- Chuang, Y., Song-yu, L. (2005). "A study on prediction of embankment settlement with the Gompertz model." *Rock and Soil Mechanics*, **26(1)**: 82-86.
- Chung, S., Lee, N., Kim, S. (2009). "Hyperbolic method for prediction of prefabricated vertical drains performance" *Journal of geotechnical and geoenvironmental engineering*, **135(10)**: 1519-1528. doi: 10.1061/(ASCE)GT.1943-5606.0000042.
- Colleselli, F., Cortellazzo, G. (1992). "Foundation behaviour of a levee in the Po Delta." Proceedings of the symposium: Prediction versus performance in geotechnical engineering, 30 Nov-4 Dec 1992, Bangkok, pp. 15-20.
- Collette, Y., Siarry, P. (2011). "*Optimisation multiobjectif: Algorithmes* ", Editions Eyrolles, pp. 328.
- Crawford, T. V. (1965). "Moisture transfer in free and forced convection." *Quarterly Journal of the Royal Meteorological Society*, **91(387)**: 18-27. doi: 10.1002/qj.49709138704.
- Crooks, J., Graham, J. (1976). "Geotechnical properties of the Belfast estuarine deposits." *Geotechnique*, **26(2)**: 293-315. doi: 10.1680/geot.1976.26.2.293.
- Culioli, J. C. (1999). "*Introduction à l'optimisation* ", Ellipses, pp. 384.
- Darwin, C. (1859). "*On the origins of species by means of natural selection* ", London Murray, pp. 502.

- Davalo, E., Naïm, P., Clément, F. (1990). "Des réseaux de neurones ", Eyrolles, pp. 232.
- Davies, P., Dennison, J. (1975). "The use of heat treatment to recover the creep properties of nimonic 115 after high temperature creep." *Metal Science*, **9(1)**: 319-323. doi: 10.1179/030634575790444793.
- Desai, C., Zhang, D. (1987). "Viscoplastic model for geologic materials with generalized flow rule." *International Journal for Numerical and Analytical Methods in Geomechanics*, **11(6)**: 603-620. doi: 10.1002/nag.1610110606.
- Devi, S. P., Devi, K. R., Prasad, D., Raju, G. (2015). "Study on consolidation and correlation with index properties of different soils in Manipur valley." *International Journal of Engineering Research and Development*, **11(05)**: 57-63.
- Dhowian, A. W. (1991). "Secondary compression of sabkha "saline" soils." *Engineering Geology*, **30(2)**: 155-169. doi: 10.1016/0013-7952(91)90041-I.
- Djedid, A., Bekkouche, A., Mamoune, S. M. A. (2001). "Identification and prediction of the swelling behavior of some soils from the Tlemcen region of Algeria ", Bulletin-Laboratoires des Ponts et Chaussées N° 233, pp. 67-76.
- Dorigo, M., Maniezzo, V., Colorni, A. (1996). "Ant system: optimization by a colony of cooperating agents." *IEEE Transactions on Cybernetics* **26(1)**: 29-41. doi: 10.1109/3477.484436.
- Dréo, J., Petrowski, A., Siarry, P., Taillard, E. (2003). "Métaheuristiques pour l'optimisation difficile ", Eyrolles, pp. 356. doi: <https://hal.archives-ouvertes.fr/hal-00843020>
- Eberhart, R., Kennedy, J. (1995). "A new optimizer using particle swarm theory." Proceedings of the Sixth International Symposium on micro machine and human science, 4-6 Oct 1995, Nagoya, Japan, pp. 39-43. doi: 10.1109/MHS.1995.494215.
- Edil, T. B., Fox, P. J., Lan, L. T. (1991). "Observational procedure for settlement of peat." Conference on geotechnical engineering for coastal development: theory and practice on soft ground, 3-6 September 1991, Yokohama, Japan, pp. 165-170.
- Fabre, G. (2005). "Fluage et endommagement des roches argileuses : évolution de la microstructure et modélisation phénoménologique". Doctoral thesis, *University Joseph Fourier*, 25 Jul 2005, Grenoble, France, pp. 314.
- Farmer, J. D., Packard, N. H., Perelson, A. S. (1986). "The immune system adaptation and machine learning." *Physica D: Nonlinear Phenomena*, **22(1)**: 187-204. doi: 10.1016/0167-2789(86)90240-X.
- Favre, J. L. (2004). "Géotechnique: sécurité des ouvrages risqués: modélisation de l'incertain fiabilité analyse des risques ", Ellipses, pp. 318
- Feo, T. A., Resende, M. G. (1989). "A probabilistic heuristic for a computationally difficult set covering problem." *Operations Research Letters*, **8(2)**: 67-71. doi: 10.1016/0167-6377(89)90002-3.
- Fleury, G. (1993). "Méthodes stochastiques et déterministes pour les problèmes NP-difficiles". Doctoral thesis *Université Blaise Pascal*, 4 septembre 1993, Clermont Ferrand, France, pp. 358.
- Fodil, A., Aloulou, W., Hicher, P. (1997). "Viscoplastic behaviour of soft clay." *Geotechnique*, **47(3)**: 581-591. doi: 10.1680/geot.1997.47.3.581.

- Fox, P. J., Edil, T. B., Lan, L.-T. (1992). "C α /C c Concept Applied to Compression of Peat." *Journal of Geotechnical Engineering*, **118(8)**: 1256-1263.
- Frontard, J. (1914). "Notice sur l'accident de la digue de Charmes ", Annales des ponts et chaussées 9^{ème} série, 23, pp. 173-292.
- Gandomi, A. H., Sajedi, S., Kiani, B., Huang, Q. (2016). "Genetic programming for experimental big data mining: A case study on concrete creep formulation." *Automation in Construction*, **70(1)**: 89-97. doi: 10.1016/j.autcon.2016.06.010.
- Ganesalingam, D. (2013). "Consolidation properties of recent dredged mud sediment and insights into the consolidation analysis". Doctoral thesis, James Cook University, 17 April 2013, North Queensland, Australia, pp. 185.
- Geem, Z. W., Kim, J. H., Loganathan, G. V. (2001). "A new heuristic optimization algorithm: harmony search." *Simulation*, **76(2)**: 60-68. doi: 10.1177/003754970107600201.
- Gestin, G., Puiatti, D. (1980). "Prévision des tassements à long terme des matériaux de remblais." Colloque international sur le compactage, 22-24 avril 1980, Paris , France, pp. 67-71.
- Gibson, R., England, G., Hussey, M. (1967). "The Theory of one-dimensional consolidation of saturated clays: finite non-Linear consolidation of thin homogeneous layers." *Geotechnique*, **17(3)**: 261-273. doi: 10.1680/geot.1967.17.3.261.
- Gioda, G. (1985). "Some remarks on back analysis and characterization problems in geomechanics." 5th international conference on numerical methods in geomechanics, 1–5 April 1985, Nagaya, Japan, pp. 47-61.
- Gioda, G., Sakurai, S. (1987). "Back analysis procedures for the interpretation of field measurements in geomechanics." *International Journal for Numerical and Analytical Methods in Geomechanics*, **11(6)**: 555-583. doi: 10.1002/nag.1610110604.
- Glover, F. (1986). "Future paths for integer programming and links to artificial intelligence." *Computers & operations research*, **13(5)**: 533-549.
- Goh, A. T. (1999). "Genetic algorithm search for critical slip surface in multiple-wedge stability analysis." *Canadian Geotechnical Journal*, **36(2)**: 382-391. doi: 10.1139/t98-110.
- Goldberg, D. E. (1989). "Genetic Algorithms in Search, Optimization and Machine Learning ", Addison Wesley Longman Publishing, pp. 372.
- Gordan, B., Armaghani, D. J., Hajihassani, M., Monjezi, M. (2016). "Prediction of seismic slope stability through combination of particle swarm optimization and neural network." *Engineering with Computers*, **32(1)**: 85-97. doi: 10.1007/s00366-015-0400-7.
- Graham, C., Harmon, R. (1983). "Stable isotope evidence on the nature of crust-mantle interactions ". *Continental basalts and mantle xenoliths*, Nantwich, UK , Shiva Nantwich, pp. 20-45.
- Graham, J., Crooks, J. H. A., Lau, S. L. K. (1988). "Yield envelopes: identification and geometric properties." *Géotechnique*, **38(1)**: 125-134. doi: 10.1680/geot.1988.38.1.125.
- Grimstad, G., Degago, S., Boumezerane, D. (2015). "Discussion of Viscous behaviour of clays in one-dimensional compression." *Canadian Geotechnical Journal*, **52(1)**: 120-120. doi: 10.1139/cgj-2013-0198.

- Güllü, H., Canakci, H., Alhashemy, A. (2016). "Development of Correlations for Compression Index." *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, **16(2)**: 344-355.
- Handayanto, R. T., Tripathi, N. K., Kim, S. M., Guha, S. (2017). "Achieving a sustainable urban form through land use optimisation: insights from Bekasi city's land-use plan (2010–2030)." *Sustainability*, **9(2)**: 221. doi: 10.3390/su9020221.
- Hanna, W. S. (1950). "Settlement studies in Egypt." *Géotechnique* **2(1)**: 33-35. doi: 10.1680/geot.1951.2.3.265.
- Hashash, Y. M., Marulanda, C., Ghaboussi, J., Jung, S. (2006). "Novel approach to integration of numerical modeling and field observations for deep excavations." *Journal of Geotechnical and Geoenvironmental Engineering*, **132(8)**: 1019-1031. doi: 10.1061/(ASCE)1090-0241(2006)132:8(1019).
- Hashash, Y., Jung, S., Ghaboussi, J. (2004). "Numerical implementation of a neural network based material model in finite element analysis." *International Journal for Numerical Methods in Engineering*, **59(7)**: 989-1005. doi: 10.1002/nme.905.
- Hayashi, H., Nishikawa, J., Yamaguchi, S., Mitachi, T., Fukuda, F. (1998). "Finite element analysis of peaty ground using a Cam Clay model." Proceedings of the International Symposium on Problematic Soils, 28-30 October, Sendai, Japan, pp. 123-127.
- Hayashi, H., Yamazoe, N., Mitachi, T., Tanaka, H., Nishimoto, S. (2012). "Coefficient of earth pressure at rest for normally and overconsolidated peat ground in Hokkaido area." *Soils and Foundations*, **52(2)**: 299-311. doi: 10.1016/j.sandf.2012.02.007.
- Hebb, D. O. (1949). *The organization of behavior: a neuropsychological theory*, Chapman and Hall, pp. 378
- Heppner, F., Grenander, U. (1990). "A stochastic nonlinear model for coordinated bird flocks." *The Ubiquity of Chaos*, **233(1)**: 233-238.
- Herling, M. M., Breu, J. (2014). "The largely unknown class of microporous hybrid materials: clays pillared by molecules." *Journal of Inorganic and General Chemistry*, **640(3)**: 547-560. doi: 10.1002/zaac.201300540.
- Himanshu, N., Kumar, V., Burman, A., Gordan, B. (2020). "Optimization of non-circular failure surface in slope based on particle swarm models." *Innovative Infrastructure Solutions*, **5(1)**: 1-9. doi: 10.1007/s41062-019-0259-3.
- Hinchberger, S. D., Rowe, R. K. (1998). "Modelling the rate-sensitive characteristics of the Gloucester foundation soil." *Canadian Geotechnical Journal*, **35(5)**: 769-789. doi: 10.1139/t98-037.
- Hinton, G. E., Sejnowski, T. J. (1983). "Optimal perceptual inference." Proceedings of the IEEE conference on Computer Vision and Pattern Recognition, 4-5 June 1983, Washington, USA, pp. 448-453.
- Honjo, Y., Kashiwagi, N. (1999). "Matching objective and subjective information in groundwater inverse analysis by Akaike's Bayesian Information Criterion." *Water Resources Research*, **35(2)**: 435-447. doi: 10.1029/98WR02365.
- Hopfield, J. J. (1982). "Neural networks and physical systems with emergent collective computational abilities." *Proceedings of the national academy of sciences*, **79(8)**: 2554-2558. doi: 10.1073/pnas.79.8.2554.
- Houkes, C. B. (2016). "Review and validation of settlement prediction methods for organic soft soils, on the basis of three case studies from the Netherlands." Doctoral thesis, *Delft University of Technology*, 14 July

2016, Delft, Netherlands, pp. 170.

- Hu, M., Li, W., Yan, K., Ji, Z., Hu, H. (2019). "Modern machine learning techniques for univariate tunnel settlement forecasting: A comparative study" *Mathematical Problems in Engineering*, **2019**. doi: 10.1155/2019/7057612.
- Huat, B. B. K. (1996). "Observational method of predicting the settlement" Proceedings of the twelfth southeast asian geotechnical conference and the fourth international conference on tropical soils, 6-10 May 1996, Kuala Lumpur, Malaysia, pp. 191-196.
- Işık, N. S. (2009). "Estimation of swell index of fine grained soils using regression equations and artificial neural networks." *Scientific Research and Essays*, **4(10)**: 1047-1056. doi: 10.5897/SRE.9000461.
- Itihara, M., Yoshikawa, S., Inoue, K., Hayashi, T., Tateishi, M., Nakajima, K. (1975). "Stratigraphy of the Plio-Pleistocene Osaka Group in Sennan-Senpoku Area, South of Osaka, Japan: A standard stratigraphy of the Osaka Group" *Journal of geosciences Osaka City University*(**19**): 1-29.
- Javadi, A. A., Rezaei, M., Nezhad, M. M. (2006). "Evaluation of liquefaction induced lateral displacements using genetic programming." *Computers and Geotechnics*, **33(4-5)**: 222-233. doi: 10.1016/j.compgeo.2006.05.001.
- Jesmani, M., Vaezi, R., Kamalzare, M. (2012). "Correlation between Ca/Cc ratio and index parameters of soils." *Quarterly Journal of Engineering Geology and Hydrogeology*, **45(2)**: 207-220.
- Jiang, J., Chen, Q., Nimbalkar, S. (2016). "Field data based method for predicting long-term settlements" *American Journal of Engineering and Applied Sciences* **9(3)**: 466-476. doi: 10.3844/ajeassp.2016.466.476.
- Jin, Y.-F., Yin, Z.-Y., Zhou, W.-H., Huang, H.-W. (2019). "Multi-objective optimization-based updating of predictions during excavation." *Engineering Applications of Artificial Intelligence*, **78**: 102-123. doi: 10.1016/j.engappai.2018.11.002.
- Kaddouri, Z., Cuisinier, O., Masrouri, F. (2019). "Influence of effective stress and temperature on the creep behavior of a saturated compacted clayey soil." *Geomechanics for Energy and the Environment*, **17**: 106-114. doi: 10.1016/j.gete.2018.09.002.
- Kalantary, F., Kordnaeij, A. (2012). "Prediction of compression index using artificial neural network." *Scientific Research and Essays*, **7(31)**: 2835-2848. doi: 10.5897/SRE12.297.
- Kalatehjari, R., Ali, N., Kholghifard, M., Hajihassani, M. (2014). "The effects of method of generating circular slip surfaces on determining the critical slip surface by particle swarm optimization." *Arabian Journal of Geosciences*, **7(4)**: 1529-1539. doi: 10.1007/s12517-013-0922-5.
- Kamei, T., Sakajo, S. (1995). "Evaluation of undrained shear behaviour of k_0 consolidated cohesive soils using elasto-viscoplastic model." *Computers and Geotechnics*, **17(3)**: 397-417. doi: 10.1016/0266-352X(95)99219-H.
- Karaboga, D. (2005). "An idea based on honey bee swarm for numerical optimization ", Technical report, Erciyes University pp. 10.
- Kardani, N., Zhou, A., Nazem, M., Shen, S. L. (2020). "Estimation of bearing capacity of piles in cohesionless soil using optimised machine learning approaches." *Geotechnical and Geological Engineering*, **38(2)**: 2271-2291. doi: 10.1007/s10706-019-01085-8.

- Kavazanjian, E., Borja, R., Jong, H. (1985). "Time-dependent deformations in clay soils." 11th international conference on soil mechanics and foundation engineering, August 1985, San Francisco, USA, pp. 535-538.
- Kaveh, A., Talatahari, S. (2010). "A novel heuristic optimization method: charged system search." *Acta Mechanica*, **213(3)**: 267-289. doi: 10.1007/s00707-009-0270-4.
- Kennedy, J. (1999). "Small worlds and mega-minds: effects of neighborhood topology on particle swarm performance." Proceedings of the 1999 congress on evolutionary computation-CEC99, Washington, USA, pp. 1931-1938. doi: 10.1109/CEC.1999.785509.
- Kennedy, J., Eberhart, R. (1995). "Particle swarm optimization." Proceedings of international conference on neural networks, 27 Nov -1 Dec 1995, pp. 1942-1948. doi: 10.1109/ICNN.1995.488968.
- Kim, S., Finno, R. J. (2019). "Inverse analysis of a supported excavation in Chicago." *Journal of Geotechnical and Geoenvironmental Engineering*, **145(9)**: 04019050. doi: 10.1061/(ASCE)GT.1943-5606.0002120.
- Kim, S., Finno, R. J. (2020). "Inverse analysis of hypoplastic clay model for computing deformations caused by excavations." *Computers and Geotechnics*, **122**: 103-499. doi: 10.1016/j.compgeo.2020.103499.
- Kirkpatrick, S., Gelatt, C. D., Vecchi, M. P. (1983). "Optimization by simulated annealing." *science*, **220(4598)**: 671-680.
- Kobashigawa, J., Youn, H. s., Iskander, M., Yun, Z. (2009). "Comparative study of genetic programming vs. neural networks for the classification of buried objects." IEEE Antennas and propagation society international symposium, 1-5 June 2009, Charleston, USA, pp. 1-4. doi: 10.1109/APS.2009.5172386.
- Koehorst, B., The, B. H. P., Teunissen, J. A. M., Lojander, M., Näätänen, A. (1992). "The trial embankments in Vaasa, Finland. A simulation with the Adachi-Oka creep model." IV international symposium on numerical models in geomechanics, 24-27 August, Swansea, Wales, pp. 767-776.
- Kohonen, T. (1982). "Self organized formation of topologically correct feature maps." *Biological Cybernetics*, **43(1)**: 59-69. doi: 10.1007/BF00337288.
- Kohonen, T., Kaski, S., Lagus, K., Salojarvi, J., Honkela, J., Paatero, V., Saarela, A. (2000). "Self organization of a massive document collection." *IEEE Transactions on Neural Networks*, **11(3)**: 574-585. doi: 10.1109/72.846729.
- Koppejan, A. (1948). "A formula combining the Terzaghi load compression relationship and the Buisman secular time effect." Proceedings of the second international conference on soil mechanics and foundation engineering, 21- 30 June 1948, Rotterdam, Netherlands, pp. 32-37.
- Koppula, S. D. (1981). "Statistical Estimation of Compression Index." *Geotechnical Testing Journal*, **4(2)**: 68-73.
- Koskinen, M. T., Haugen, T. O., Primmer, C. R. (2002). "Contemporary fisherian life-history evolution in small salmonid populations." *Nature*, **419(9)**: 826-830. doi: 10.1038/nature01029.
- Kuok, K. K., Harun, S., Shamsuddin, S. (2010). "Particle swarm optimization feedforward neural network for modeling runoff." *International Journal of Environmental Science and Technology*, **7(1)**: 67-78. doi: 10.1007/BF03326118.
- Ladd, C. C., Foott, R., Ishihara, K., Schlosser, F., Poulos, H. G. (1977). "Stress deformation and strength

- characteristics." Proceedings of the 9th international conference on soil mechanics and foundation engineering, 9-13 December 1977, Tokyo, Japan, pp. 421-494.
- Latorre, B., Moret-Fernández, D. (2019). "Simultaneous estimation of the soil hydraulic conductivity and the van Genuchten water retention parameters from an upward infiltration experiment." *Journal of Hydrology*, **572(1)**: 461-469. doi: 10.1016/j.jhydrol.2019.03.011.
- Lecampion, B., Constantinescu, A., Nguyen Minh, D. (2002). "Parameter identification for lined tunnels in a viscoplastic medium." *International Journal for Numerical and Analytical Methods in Geomechanics*, **26(12)**: 1191-1211. doi: 10.1002/nag.241.
- Lee, J. N., Kim, Y. G. (1999). "Effect of partnership quality on IS outsourcing success: conceptual framework and empirical validation." *Journal of Management Information Systems*, **15(4)**: 29-61. doi: 10.1080/07421222.1999.11518221.
- Lei, G., Qiu yue, Z., Xiang juan, Y., Zhi hui, C. (2014). "Analysis and model prediction of subgrade settlement for Linhai highway in China" *Electronic Journal of Geotechnical Engineering*, **19(1)**: 2-11.
- Leonards, G. A. (1977). "Panel discussion." Proceedings of the 9th international conference on soil mechanics and foundation engineering, 9-13 December 1977, Tokyo, Japan, pp. 384 – 386.
- Lepetit Aimon, G. (2018). "Architecture complètement convolutive à champ d'activation large pour la segmentation sémantique de la vasculature rétinienne dans les images de fond d'oeil". Doctoral thesis, *École Polytechnique de Montréal*, 2 Aout 2018, Montréal, Canada, pp. 140.
- Lepidas, I., Magnan, J. (1990). "Fluage et consolidation des sols argileux : modélisation numérique ", Rapport de Recherche de Laboratoire des Ponts et Chaussées N°157, pp. 167.
- Leroueil, S. (1996). "Importance of strain rate and temperature effects in geotechnical engineering." *Measuring and Modeling Time Dependent Soil Behaviour*, **61(1)**: 1-60.
- Leroueil, S., Kabbaj, M., Tavenas, F., Bouchard, R. (1985). "Stress strain rate relation for the compressibility of sensitive natural clays." *Geotechnique*, **35(2)**: 159-180. doi: 10.1680/geot.1985.35.2.159.
- Leroueil, S., Tavenas, F. (1977). "Effects of stresses and time on yield of clays." Proceedings of 9th international conference on soil mechanics and foundation engineering, Tokyo, Japan, pp. 319–326.
- Levasseur, S., Malécot, Y., Boulon, M., Flavigny, E. (2005). "Analyse inverse d'une courbe pressiométrique par algorithme génétique." Symposium International ISP5, 22 au 24 août 2005, Paris, France.
- Li, A. J., Fatty, A., Yang, I. (2020). "Use of evolutionary computation to improve rock slope back analysis." *Applied Sciences*, **10(6)**: 2012. doi: 10.3390/app10062012.
- Ling, H. I., Leshchinsky, D., Mohri, Y., Kawabata, T. (1998). "Estimation of municipal solid waste landfill settlement." *Journal of Geotechnical and Geoenvironmental Engineering*, **124(1)**: 21-28. doi: 10.1061/(ASCE)1090-0241(1998)124:1(21).
- Liu, L., Moayedi, H., Rashid, A. S. A., Rahman, S. S. A., Nguyen, H. (2019). "Optimizing an ANN model with genetic algorithm (GA) predicting load-settlement behaviours of eco-friendly raft-pile foundation (ERP) system" *Engineering with Computers*: 1-13. doi: 10.1007/s00366-019-00767-4.
- Lo, K. Y. (1961). "Secondary compression of clays." *Journal of the Soil Mechanics and Foundations Division*,

87(4): 61-88.

- Maamri, I., El Ouafi, A., Barka, N. (2014). "Prediction of 4340 steel hardness profile heat-treated by laser using artificial neural networks and multi regression approaches." *International Journal of Engineering and Innovative Technology*, **4(6)**: 14-22.
- Magnan, J. P. (1984). "Modélisation numérique du comportement des argiles molles naturelles.". Thèse de doctorat d'Etat : Sciences physiques, *Université Pierre et Marie Curie*, Paris, pp. 255.
- Magnan, J. P., Bertania, G., Khemissa, M., P., R. (2001). "A propos des Indices de fluage déterminés à l'oedomètre." 15th International conference on soil mechanics and foundation engineering, 1 September 2001, Istanbul, Turkey.
- Magnan, J. P., Breton, J. P., Rajo, t. J. P., Tar, H. (1999). "Fluage des sols mous des remblais et des fondations superficielles." Proceedings of the twelfth european conferences on soil mechanics and geotechnical engineering, 7-10 June 1999, Amsterdam, Netherlands, pp. 1121-1126.
- Magnan, J. P., Deroy, J. M. (1980). "*Analysis graphic des courbes de consolidation oedométrique* pp. 45–52.
- Magnan, J., Humbert, P., Belkeziz, A., Mouratidis, A. (1982). "Finite element analysis of soil consolidation, with special reference to the case of strain hardening elastoplastic stress-strain models." 4th International conference on numerical methods in geomechanics, 31 May -4 June 1982, Edmonton, Canada, pp. 327-336.
- Magnan, J.-P., Mieussens, C., Soyeux, B., Vautrain, J. (1985). "*Essais oedométriques*.", Laboratoire Central des Ponts et Chaussées, Méthodes d'essais LPC N° 13, pp. 83.
- Matsuoka, H., Sakakibara, K. (1987). "A constitutive model for sands and clays evaluating principal stress rotation." *Soils and foundations*, **27(4)**: 73-88. doi: 10.3208/sandf1972.27.4_73.
- McCabe, B. A., Sheil, B. B., Long, M. M., Buggy, F. J., Farrell, E. R. (2014). "Empirical correlations for the compression index of Irish soft soils." *Geotechnical Engineering*, **167(6)**: 510-517. doi: 10.1680/geng.13.00116.
- McCarthy, J., Minsky, M., Rochester, N., Shannon, C. (1956). "A proposal for the dartmouth research project in artificial intelligence." *Artificial Intelligence Magazine*, **27(4)**: 12-14.
- McCombie, P., Wilkinson, P. (2002). "The use of the simple genetic algorithm in finding the critical factor of safety in slope stability analysis." *Computers and Geotechnics*, **29(8)**: 699-714. doi: 10.1016/s0266-352x(02)00027-7.
- McCulloch, W. S., Pitts, W. (1943). "A logical calculus of the ideas immanent in nervous activity." *The Bulletin of Mathematical Biophysics*, **5(4)**: 115-133. doi: 10.1007/BF02478259.
- Mesri, G. (1973). "Coefficient of secondary compression." *Journal of the Soil Mechanics and Foundations Division*, **99(1)**: 123-137.
- Mesri, G. (2003). "Primary compression and secondary compression." *Geotechnical Special Publication*, **119(1)**: 122-166. doi: 10.1061/40659(2003)5.
- Mesri, G., Castro, A. (1987). " C_u/C_c concept and K_0 during secondary compression." *Journal of Geotechnical Engineering*, **113(3)**: 230-247.
- Mesri, G., Choi, Y. K. (1985). "Settlement analysis of embankments on soft clays." *Journal of Geotechnical*

Engineering, **111(4)**: 441-464. doi: doi:10.1061/(ASCE)0733-9410(1985)111:4(441).

- Mesri, G., Godlewski, P. M. (1977). "Time-and stress-compressibility interrelationship." *Journal of geotechnical and geoenvironmental engineering*, **103(5)**: 417-430.
- Mesri, G., Huvaj Sarihan, N. (2009)."The Asaoka method revisited." 17th International Conference on Soil Mechanics and Geotechnical Engineering, Alexandria, Egypt, pp. 131-134. doi: 10.3233/978-1-60750-031-5-131.
- Mesri, G., M, A., Funk, J. R., Asce, S. M. (2015). "Settlement of the Kansai international airport islands" *Journal of Geotechnical and Geoenvironmental Engineering*, **141(2)**: 1-16. doi: 10.1061/(ASCE)GT.1943-5606.0001224.
- Mesri, G., Stark, T., Ajlouni, M., Chen, C. (1997). "Secondary compression of peat with or without surcharging." *Journal of Geotechnical Engineering*, **123(5)**: 411-420. doi: 10.1061/(asce)1090-0241(1997)123:5(411).
- Mestat, P. (1993). "*Lois de comportement des géomatériaux et modélisation par la méthode des éléments finis*"., Etudes et Recherches des Laboratoires des Ponts et Chaussées-Serie Geotechnique N° 52, pp. 193.
- Michali, A. (1994). "Méthode pour l'identification des paramètres d'une loi élastoplastique à partir d'essais de laboratoire et in situ : Modélisation numérique du tassement d'un remblai sur sol compressible". Doctoral thesis, Ecole Centrale Paris, 12 Mars 1994, Châtenay Malabry, France, pp. 167.
- Mimura, M., Jeon, B. G. (2013). "Interactive behavior of pleistocene marine foundation of existing 1st phase island due to construction of 2nd phase island of Kansai international airport" *Soils and Foundations*, **53(3)**: 375-394. doi: 10.1016/j.sandf.2013.04.001.
- Mimura, M., Teunissen, J. A. M. (1995)."Deformation analysis of peaty clay foundation due to highway embankment in Rotterdam." *Compression and Consolidation Clayey Soils*, Balkema, pp. 709-714.
- Ming Hsu, L., Tung, C. P., Chung Hsiung, S., Fu Hsiung, Y. (2006). "Estimating seasonal basin rainfall using tabu search." *TAO: Terrestrial, Atmospheric and Oceanic Sciences*, **17(1)**: 295. doi: 10.3319/TAO.2006.17.1.295(Hy).
- Minsky, M., Papert, S. (1969). "An introduction to computational geometry." *IEEE Transactions on Computers* **18(6)**: 572 - 572. doi: 10.1109/T-C.1969.222718.
- Mitachi, T., Fukuda, F. (1998)."Applicability of cam clay model as a constitutive relation for consolidation-deformation coupled three dimensional FE analysis for highly organic soft ground." Proceeding of the international symposium on problematic soils, 12-15 October 1998, Rotterdam, Netherlands, pp. 65-68.
- Mitchell, J. K. (1964). "Shearing resistance of soils as a rate process." *Journal of the Soil Mechanics and Foundations Division*, **90(37-73)**. doi: 10.1016/0022-4898(64)90023-0.
- Mitchell, J. K. (1994). "*Fundamentals of soil behaviour*"., John Wiley and Sons Inc, pp. 440
- Mohammad Ali, H. A. (2014). "Implementation of a critical state soft soil Creep model with shear stiffness". Thesis, *Norwegian University of Science and Technology*, 6 June 2014, Trondheim, pp. 120.
- Mohammadi Bayazidi, A., Wang, G.-G., Bolandi, H., Alavi, A. H., Gandomi, A. H. (2014). "Multigene genetic programming for estimation of elastic modulus of concrete" *Mathematical Problems in Engineering*, **7(1)**: 1-18. doi: 10.1155/2014/474289.

- Moody, J., Darken, C. J. (1989). "Fast learning in networks of locally-tuned processing units." *Neural Computation*, **1**(2): 281-294. doi: 10.1162/neco.1989.1.2.281.
- Moutsopoulos, K. N., Papaspyros, J. N., Tsihrintzis, V. A. (2017). "Management of groundwater resources using surface pumps: optimization using genetic algorithms and the tabu search method." *Korean Society of Civil Engineers*, **21**(7): 2968-2976. doi: 10.1007/s12205-017-1013-z.
- Näätänen, A., Vepsäläinen, P., Lojander, M. (1998). "Finite element calculations on Haarajoki test embankment". *Application of Numerical Methods to Geotechnical Problems*, Springer, Vienna, Vol. 397, pp. 151-160. doi: 10.1007/978-3-7091-2512-0_14.
- Nagaraj, H., Sridharan, A., Mallikarjuna, H. (2012). "Re-examination of undrained strength at Atterberg limits water contents." *Geotechnical and Geological Engineering*, **30**(4): 727-736. doi: 10.1007/s10706-011-9489-7.
- Nagaraj, T. S., Murthy Srinivasa, B. R. (1985). "Prediction of the preconsolidation pressure and recompression index of soils." *Geotechnical Testing Journal* **8**(4): 199-202. doi: 10.1520/GTJ10538J.
- Nagaraj, T., Murthy, B. S., Vatsala, A., Joshi, R. (1990). "Analysis of compressibility of sensitive soils." *Journal of Geotechnical Engineering*, **116**(1): 105-118.
- Nakase, A. (1987). "Kansai international airport-construction of man-made island." Proceedings of the 8th asian regional conference on soil mechanics and foundation engineering, 20-24 July 1987, Kyoto, Japan, pp. 87-101.
- Neher, H., Wehnert, M., Bonnier, P. (2001). "An evaluation of soft soil models based on trial embankments." Proceedings of the 10th International Conference on Computer Methods and Advances in Geomechanics, 7-12 January 2001, Tucson, Arizona, USA, pp. 373-379.
- Newland, P. L., Allely, B. H. (1960). "A study of the consolidation characteristics of a clay." *Geotechnique*, **10**(2): 62-74. doi: 10.1680/geot.1960.10.2.62.
- Newson, T. (1997). "Modeling the yielding behaviour of natural soft clays." Proceedings of the 14th international conference on soil mechanics and foundation engineering, 6-12 September 1997, Hamburg, Germany, pp. 381-386.
- Ng, K. S., Chew, Y. M., Lazim, N. I. A. (2018). "Prediction of Consolidation Characteristics from Index Properties." *International Conference on Civil and Environmental Engineering*, **65**(1): 1-5. doi: 10.1051/e3sconf/20186506004
- Nguyen Pham PT. , T. o. D. (2008). "Etude en place et au laboratoire du comportement en petites déformations des sols argileux naturels". Doctoral thesis, École Nationale des Ponts et Chaussées, 18 janvier 2008, Paris, France, pp. 2016.
- Nkiac. (2012). *New Kansai International Airport Company*, Retrieved: 05 Jan 2019, from: <http://www.nkiac.co.jp>
- Nougier, J. P. (2001). "*Méthode de calcul numérique volume 1: Systeme d'équations*"., Hermes Science Publications, pp. 333.
- Ohta, H., Iizuka, A. (1988). "Soil-structure interaction related to actual construction sequences." Proceedings of the 6th international conference on numerical methods in geomechanics 11-15 April 1988, Innsbruck,

Austria, pp. 2043-2050.

- Ohta, H., Iizuka, A., Mitsuhashi, Y., Nabetani, M. (1991). "Deformation analysis of anisotropically consolidated clay foundation loaded by 5 embankments." International association for computer methods and advances in geomechanics, 6-10 May 1991, Cairns, Australia, pp. 1017-1022
- Onyejekwe, S., Kang, X., Ge, L. (2015). "Assessment of empirical equations for the compression index of fine-grained soils in Missouri." *Bulletin of Engineering Geology and the Environment*, **74(3)**: 705-716. doi: 10.1007/s10064-014-0659-8.
- Ozutsumi, O., Iai, S., Nakahara, T. (2015). "Two-dimensional Effective Stress Analysis on Consolidation of Clay under Highway Embankment and Its Seismic Response after Consolidation." 6th International Conference on Earthquake Geotechnical Engineering, 1-4 November 2015, Christchurch, New Zealand
- Pak, A., Maleki, J., Aghakhani, N., Yousefi, M. (2019). "Numerical investigation of stability of deep excavations supported by soil-nailing method." *Geomechanics and Geoengineering*: 1-18. doi: 10.1080/17486025.2019.1680878.
- Park, H. I., Lee, S. R. (2011). "Evaluation of the compression index of soils using an artificial neural network." *Computers and Geotechnics*, **38(4)**: 472-481. doi: 10.1016/j.compgeo.2011.02.011.
- Park, H., Cho, C. (2010). "Neural network model for predicting the resistance of driven piles" *Marine Georesources and Geotechnology*, **28(4)**: 324-344.
- Parker, R. L. (1977). "Understanding inverse theory." *Annual Review of Earth and Planetary Sciences*, **5(1)**: 35-64. doi: 10.1146/annurev.ea.05.050177.000343.
- Patel, R. S., Desai, M. (2010). "CBR predicted by index properties for alluvial soils of South Gujarat." Proceedings of the Indian geotechnical conference, 16-18 December 2010, Mumbai, India, pp. 79-82.
- Pedro, A. M., Zdravković, L., Potts, D., e Sousa, J. A. (2017). "Derivation of model parameters for numerical analysis of the Ivens shaft excavation." *Engineering Geology*, **217**: 49-60. doi: 10.1016/j.enggeo.2016.12.005.
- Pernot, S., Lamarque, C.-H. (1999). "Application of neural networks to the modelling of some constitutive laws." *Neural Networks*, **12(2)**: 371-392. doi: 10.1016/S0893-6080(98)00115-4.
- Perzyna, P. (1963). "The constitutive equations for rate sensitive plastic materials." *Quarterly of applied mathematics*, **20(4)**: 321-332. doi: 10.1090/qam/144536.
- Perzyna, P. (1966). "Fundamental problems in viscoplasticity." *Advances in applied mechanics*, **9(1)**: 243-377. doi: 10.1016/S0065-2156(08)70009-7.
- Phanikumar, B., Sharma, R. S. (2007). "Volume change behavior of fly ash-stabilized clays." *Journal of Materials in Civil Engineering*, **19(1)**: 67-74. doi: 10.1061/(ASCE)0899-1561(2007)19:1(67).
- Pinto, C. S. (2001). "Considerations of Asaoka's method". *Soils and Rocks*, **24 (1)**: 95 -100.
- Poggio, T., Girosi, F. (1990). "Regularization algorithms for learning that are equivalent to multilayer networks." *Science*, **247(4945)**: 978-982. doi: 10.1126/science.247.4945.978.
- Poppe, V. F., Paskevich, J. C., Hathaway, Blackwood, D. S. (2018). *A laboratory manual for X-Ray powder diffraction*, Geological survey: Open File Report 1-41, from: <http://www.usgs.gov>.

- Powell, M. J. (1985). "Radial basis functions for multivariable interpolation: a review." IMA Conference on algorithms for approximation of functions and data, 5-7 July 1985, Shrivenham, England, pp. 143–167.
- pp. 1-9.
- Prager, W. (1955). "The Theory of Plasticity: A Survey of Recent Achievements." *169(1)*: 41-57. doi: 10.1243/pime_proc_1955_169_015_02.
- Raju, P. N., Pandian, N., Nagaraj, T. (1995). "Analysis and estimation of the coefficient of consolidation." *Geotechnical Testing Journal*, **18(2)**: 252-258. doi: 10.1520/GTJ10325J.
- Recordon, E. (1988). "*Tassement des ouvrages au cours du temps: Méthode d'interprétation des mesures* ", Ingénieurs et Architectes Suisses N°7, pp.
- Redman, P. G., Poulos, H. G. (1984). "Study of two field cases involving undrained creep." *Journal of Geotechnical Engineering*, **110(9)**: 1307-1321. doi: 10.1061/(ASCE)0733-9410(1984)110:9(1307).
- Rendon herrero, O. (1983). "Universal Compression Index Equation." *Journal of Geotechnical Engineering*, **109(5)**: 755-761. doi: 10.1061/(ASCE)0733-9410(1983)109:5(755).
- Reynolds, C. W. (1987). "Flocks herds and schools: A distributed behavioral model." 14th Annual Conference on computer graphics and interactive techniques, 27-31 July 1987, California, USA, pp. 25-34. doi: 10.1145/37402.37404.
- Rezania, M., Javadi, A. A. (2007). "A new genetic programming model for predicting settlement of shallow foundations." *Canadian Geotechnical Journal*, **44(12)**: 1462-1473. doi: 10.1139/T07-063.
- Roscoe, K. H., Burland, J. (1968). "On the generalized stress-strain behaviour of wet clay." *Cambridge University Press*: 553–609.
- Roscoe, K., Schofield, A., Thurairajah, A. (1963). "Yielding of clays in states wetter than critical." *Geotechnique*, **13(3)**: 211-240.
- Rosenblatt, F. (1958). "The perceptron: a probabilistic model for information storage and organization in the brain." *Psychological Review*, **65(6)**: 386-408. doi: 10.1037/h0042519.
- Roy, T., Chattopadhyay, B., Roy, S. (2011). "California bearing ratio evaluation and estimation: A study of comparison." Proceedings of the Indian geotechnical conference, 15-17 Dec 2011, Mumbai , India, pp. 19-22.
- Sadok, A. (2016). "Formulation de matériaux de construction à base de Sous-produits industriels avec des méthodes issues de l'intelligence artificielle". Doctoral thesis, Université de Lille 1, 20 Septembre 2016 ,Lille , France, pp. 186.
- Samarajiva, P., Macari, E. J., Wathugala, W. (2005). "Genetic algorithms for the calibration of constitutive models for soils." *International Journal of Geomechanics*, **5(3)**: 206-217. doi: 10.1061/(asce)1532-3641(2005)5:3(206).
- Samieh, A. (2002). "Analysis of earth embankments constructed on soft clay reinforced by stone columns." Numerical Methods in Geotechnical Engineering, 4-6 septembre 2002, Paris, France, pp. 471-478.
- Santamarina, J. C., Fratta, D. (1998). "*Introduction to discrete signals and inverse problems in civil engineering* ", Amer Society of Civil Engineers, pp. 327.

- Sastry, K., Goldberg, D., Kendall, G. (2005). "Genetic algorithms ". *Search methodologies*, Springer, pp. 97-125. doi: 10.1007/0-387-28356-0_4.
- Schofield, A., Wroth, P. (1968). "*Critical state soil mechanics* ", McGraw Hill, pp. 310.
- Shahanguian, S. (1981). "*Détermination expérimentale des courbes d'état limite de l'argile organique de Cubzac-les-Ponts* ", Rapport de Recherche de Laboratoire des Ponts et Chaussées N°106, pp. 79.
- Shahin, M. A., Jaksa, M. B., Maier, H. R. (2002). "Artificial neural network based settlement prediction formula for shallow foundations on granular soils." *Australian Geomechanics: Journal and News of the Australian Geomechanics Society*, **37(4)**: 45.
- Shahin, M. A., Jaksa, M. B., Maier, H. R. (2008). "State of the art of artificial neural networks in geotechnical engineering." *Electronic Journal of Geotechnical Engineering*, **1(2)**: 1-26.
- Shahin, M. A., Jaksa, M. B., Maier, H. R. (2009). "Recent advances and future challenges for artificial neural systems in geotechnical engineering applications." *Advances in Artificial Neural Systems*, **9(1)**: 1-5. doi: 10.1155/2009/308239.
- Sheeran, D., Krizek, R. (1971). "Preparation of homogeneous soil samples by slurry consolidation." *Journal of Materials*, **6(2)**: 356-373.
- Shen, Z. P., Chen, W. (2017). "On the improvement of PSO scripts for slope stability analysis." 8th International conference on swarm intelligence, 1 August 2017, Fukuoka, Japan, pp. 174-179. doi: 10.1007/978-3-319-61824-1_19.
- Siarry, P. (2014). "*Métaheuristiques* ", Editions Eyrolles, pp. 524.
- Sidarta, D., Ghaboussi, J. (1998). "Constitutive modeling of geomaterials from non-uniform material tests." *Computers and Geotechnics*, **22(1)**: 53-71. doi: 10.1016/S0266-352X(97)00035-9.
- Singh, A., Noor, S. (2012). "Soil compression index prediction model for fine grained soils." *International Journal of Innovations in Engineering and Technology* **1(4)**: 34-37.
- Sivasithamparam, N., Rezanian, M. (2017). "The comparison of modelling inherent and evolving anisotropy on the behaviour of a full-scale embankment." *International Journal of Geotechnical Engineering*, **11(4)**: 343-354. doi: 10.1080/19386362.2016.1221575.
- Skempton, A. W., Jones, O. (1944). "Notes on the compressibility of clays." *Quarterly Journal of the Geological Society*, **100(1)**: 119-135. doi: 10.1144/GSL.JGS.1944.100.01-04.08.
- Solanki, C. H., Desai, M. D. (2008). "Role of atterberg limits on time rate settlement of alluvial deposits." *Journal of Engineering and Technology*, **21(1)**: 12-15.
- Sridharan, A., Prakash, K. (1998). "Characteristic water contents of a fine-grained soil-water system." *Geotechnique*, **48(3)**: 337-346. doi: 10.1680/geot.1998.48.3.337.
- Sridharan, A., Rao, A. S. (1982). "Mechanisms controlling the secondary compression of clays." *Geotechnique*, **32(3)**: 249-260. doi: 10.1680/geot.1982.32.3.249.
- Sridharan, A., Rao, G. V. (1973). "Mechanisms controlling volume change of saturated clays and the role of the effective stress concept." *Geotechnique*, **23(3)**: 359-382. doi: 10.1680/geot.1973.23.3.359.

- Sun, D., Matsuoka, H., Ishii, H. (2001). "An anisotropic hardening elastoplastic model for clay and sand and its application to numerical analysis." Proceedings of the 10th International Conference on Computer Methods and Advances in Geomechanics, 7-12 January 2001, Tucson, Arizona, USA, pp. 407.
- Sun, D., Matsuoka, H., Yao, Y., Ishii, H. (2004). "An anisotropic hardening elastoplastic model for clays and sands and its application to FE analysis." *Computers and Geotechnics*, **31(1)**: 37-46. doi: 10.1016/j.compgeo.2003.11.003.
- Talbi, E. G. (2009). "*Metaheuristics: from design to implementation* ", John Wiley and Sons, 74, pp. 624.
- Tan, C. C., Tung, C. P., Tsai, F. T. C. (2008). "Applying zonation methods and Tabu search to improve the ground water modeling." *Journal of the American Water Resources Association*, **44(1)**: 107-120. doi: 10.1111/j.1752-1688.2007.00141.x.
- Tan, S., Chew, S. (1996). "Comparison of the hyperbolic and Asaoka observational method of monitoring consolidation with vertical drains" *Soils and foundations*, **36(3)**: 31-42. doi: 10.3208/sandf.36.3_31.
- Tang, Z., De Almeida, C., Fishwick, P. A. (1991). "Time series forecasting using neural networks vs Box Jenkins methodology" *Simulation*, **57(5)**: 303-310. doi: 10.1177/003754979105700508.
- Tavenas, F., Leroueil, S. (1979). "Clay behaviour and the selection of design parameters." Proceedings of the 7th European Conference on Soil Mechanics and Foundation Engineering, pp. 281-291.
- Taylor, D. W. (1942). "*Research on consolidation of clays* ", Massachusetts Institute of Technology, pp. 147.
- Tennekoon, J., Van Gemert, D., Maertens, J., Houtmeyers, J., Erven, J. (2002). "*Recycling and Reuse of Sewage Sludge: The reuse of industrial sludges for the construction of reservoir dams.* ", Thomas Telford Publishing, pp. 203-216. doi:10.1680/raross.29927.0017.
- Ter-Stepanian, G. (1996). "*Concentration du fluage avec le temps* ", Revue Française de Géotechnique N° 74, pp. 31-43. doi:10.1051/geotech/1996074031.
- Terzaghi, K. v. (1923). "Calculation of permeability from hydrodynamic tension." *Mathematics and science class mathematics, astronomy, physics, meteorology and technology*, **132(4)**: 105-124.
- Terzaghi, K., Peck, R. B., Mesri, G. (1996). "*Soil mechanics in engineering practice* ", John Wiley and Sons, pp. 1-592.
- The, B. H., Termaat, R. J., Vermeer, P. A. (1998). "A viscoplastic creep model for the engineering practice." Proceeding of the international symposium on problematic soils 12-15 October 1998, Rotterdam, Netherlands, pp. 657-660.
- Thépot, O. (2004). "Prise en compte des caractéristiques en petites déformations des sols dans l'étude du comportement des collecteurs enterrés". Thèses doctorat, *L'école nationale des ponts et chaussées*, 5 April 2004, Paris, France, pp. 267.
- Thinh, P., Tuan, H., Bien, D. (2017). " Research on Correlation between Compression index (Cc) and Other Properties of Soil for Geotechnical Design in Coastal Regions of Viet Nam and Cambodia." *MedCrave Online Journal of Civil Engineering*, **2(3)**: 97-101. doi: 10.15406/mojce.2017.02.00034.
- Thompson, J. B., Palmer, L. A. (1951). "*Report of consolidation tests with peat* ", Symposium on consolidation testing of soil ASTM N° 126, pp. 8. doi:10.1520/STP48292S.

- Todoroff, P., Lorion, R., Luk, J.-D. L. S. (1998). "L'utilisation des algorithmes génétiques pour l'identification de profils hydriques de sol à partir de courbes réflectométriques." *Comptes Rendus de l'Académie des Sciences-Series IIA-Earth and Planetary Science*, **327(9)**: 607-610. doi: 10.1016/S1251-8050(99)80114-1.
- Tsukada, Y., Yasuhara, K. (1995). "Scale effects in one-dimensional consolidation of clay." International symposium on compression and consolidation of clayey soils, 10-12 May 1995, Hiroshima, Japan, pp. 211-216.
- Van veen, J. A., Paul, E. A. (1981). "Organic carbon dynamics in grassland soils. 1. Background information and computer simulation." *Canadian Journal of Soil Science*, **61(2)**: 185-201. doi: 10.4141/cjss81-024.
- Vepsäläinen, P., Arkima, O., Lojander, M., Näätänen, A. (1991). "The trial embankments in Vaasa and Paimio, Finlande." 10th European conference on soil mechanics and foundation engineering, 26-30 May 1991, Florence, Italy, pp. 633-640.
- Vuailat, P. (1980). "Propriétés visqueuses d'une argile: expériences et formulation incrémentale". Doctoral thesis, *Université Joseph Fourier*, 5 Février 1980, Grenoble, France, pp. 167.
- Wang, Z. Z., Goh, S. H., Koh, C. G., Smith, I. F. C. (2019). "An efficient inverse analysis procedure for braced excavations considering three-dimensional effects." *Computers and Geotechnics*, **107**: 150-162. doi: 10.1016/j.compgeo.2018.12.004.
- Wheeler, S. J., Näätänen, A., Karstunen, M., Lojander, M. (2003). "An anisotropic elastoplastic model for soft clays." *Canadian Geotechnical Journal*, **40(2)**: 403-418. doi: 10.1139/t02-119.
- Williams, B. M. (1998). "New trading dimensions: how to profit from chaos in stocks, bonds, and commodities", John Wiley and Sons, 72, pp. 288.
- Wong, P. (1975). "Yielding and plastic flow of sensitive cemented clay." *Geotechnique*, **25(4)**: 763-782. doi: 10.1680/geot.1975.25.4.763.
- Wroth, C., Simpson, B. (1972). "Part II-Finite Element Computations: An Induced Failure at a Trial Embankment." Performance of earth and earth supported Structures, 11-14 June 1972, Lafayette, Indiana, USA, pp. 65-79.
- Yamagami, T., Jiang, J., Ueta, Y. (1997). "Back calculation of strength parameters for landslide control works using neural networks." Proceedings of the 9th international Conference computer methods and advances in geomechanics, 1 Jan 1997, Wuhan, China, pp. 57-66.
- Yang, X. (2008). "Nature-Inspired Metaheuristic Algorithms, 1st." *Frome, UK: Luniver Press, Bristol, United Kingdom*.
- Yang, X.-S. (2010). "Nature inspired metaheuristic algorithms", Luniver press, pp. 148.
- Yang, X.-S., Deb, S. (2009). "Cuckoo search via levy flights." World congress on nature and biologically inspired computing, 9-11 December 2009, Coimbatore, India, pp. 210-214.
- Yao, D. T. C., Znidarcic, D. (1997). "Crust formation and desiccation characteristics for phosphatic clays: User's manual for computer program CONDES0.", The Florida Institute of Phosphate Research, pp. 115.
- Ye, L., Jin, Y. u., Shen, S. o., Sun, P. i., Zhou, C. (2016). "An efficient parameter identification procedure for soft sensitive clays." [journal article]. *Journal of Zhejiang University*, **17(1)**: 76-88. doi:

10.1631/jzus.A1500031.

- Yin, J.-H., Graham, J. (1989). "Viscous elastic plastic modelling of one-dimensional time-dependent behaviour of clays." *Canadian Geotechnical Journal*, 26(2): 199-209. doi: 10.1139/t89-029.
- Yin, J.-H., Graham, J. (1989). "Viscous–elastic–plastic modelling of one-dimensional time-dependent behaviour of clays." *Canadian Geotechnical Journal*, 26(2): 199-209.
- Yin, Z. Y., Jin, Y. F., Shen, S. L., Huang, H. W. (2017). "An efficient optimization method for identifying parameters of soft structured clay by an enhanced genetic algorithm and elastic–viscoplastic model." *Acta Geotechnica*, 12(4): 849-867. doi: 10.1007/s11440-016-0486-0.
- Yin, Z. Y., Jin, Y. F., Shen, S. L., Huang, H. W. (2017). "An efficient optimization method for identifying parameters of soft structured clay by an enhanced genetic algorithm and elastic–viscoplastic model." *Acta Geotechnica*, 12(4): 849-867. doi: 10.1007/s11440-016-0486-0.
- Yin, Z. Y., Zhu, Q., Yin, J., Ni, Q. (2014). "Stress relaxation coefficient and formulation for soft soils." *Géotechnique*, 4(1): 45-51. doi: 10.1680/geolett.13.00070.
- Yin, Z.-Y., Chang, C. S. (2009). "Microstructural modelling of stress-dependent behaviour of clay." *International Journal of Solids and Structures*, 46(6): 1373-1388. doi: 10.1016/j.ijsolstr.2008.11.006.
- Yin, Z.-Y., Chang, C. S., Karstunen, M., Hicher, P.-Y. (2010). "An anisotropic elastic–viscoplastic model for soft clays." *International Journal of Solids and Structures*, 47(5): 665-677. doi: 10.1016/j.ijsolstr.2009.11.004.
- Yin, Z.-Y., Jin, Y.-F., Shen, S.-L., Huang, H.-W. (2017). "An efficient optimization method for identifying parameters of soft structured clay by an enhanced genetic algorithm and elastic–viscoplastic model." *Acta Geotechnica*, 12(4): 849-867.
- Yin, Z.-Y., Karstunen, M. (2011). "Modelling strain-rate-dependency of natural soft clays combined with anisotropy and destructuration." *Acta Mechanica Solida Sinica*, 24(3): 216-230. doi: 10.1016/S0894-9166(11)60023-2.
- Yin, Z.-Y., Karstunen, M. (2011). "Modelling strain-rate-dependency of natural soft clays combined with anisotropy and destructuration." *Acta Mechanica Solida Sinica*, 24(3): 216-230. doi: 10.1016/S0894-9166(11)60023-2.
- Yin, Z.-Y., Zhu, Q.-Y., Zhang, D.-M. (2017). "Comparison of two creep degradation modeling approaches for soft structured soils." *Acta Geotechnica*, 12(6): 1395-1413.
- Yin, Z.-Y., Zhu, Q.-Y., Zhang, D.-M. (2017). "Comparison of two creep degradation modeling approaches for soft structured soils." *Acta Geotechnica*, 12(6): 1395-1413.
- Yoon, G. L., Kim, B. T. (2006). "Regression analysis of compression index for Kwangyang marine clay." *Korean Society of Civil Engineers*, 10(6): 415-418. doi: 10.1007/BF02823980.
- Yoon, G. L., Kim, B. T., Jeon, S. S. (2004). "Empirical correlations of compression index for marine clay from regression analysis." *Canadian Geotechnical Journal*, 41(6): 1213-1221. doi: 10.1139/t04-057.
- Zhang, W., Zhang, Y., Goh, A. T. (2017). "Multivariate adaptive regression splines for inverse analysis of soil and wall properties in braced excavation." *Tunnelling and Underground Space Technology*, 64(1): 24-33.

doi: 10.1016/j.tust.2017.01.009.

Zhang, Y., Su, G., Liu, B., Li, T. (2020). "A novel displacement back analysis method considering the displacement loss for underground rock mass engineering." *Tunnelling and Underground Space Technology*, **95**: 103141. doi: 10.1016/j.tust.2019.103141.

Zheng, H., Zhang, S., Sun, X. (2017). "Classification recognition of anchor rod based on PSO-SVM." 29th Chinese control and decision conference, 28-30 May 2017, Chongqing, China, pp. 2207-2212.

Zhou, X., Zhang, Q., Zeng, Y.-h., Sun, G.-c. (2011). "Contrastive Analysis on Exponential Fitting and Hyperbolic Fitting in Settlement Prediction of Soft Foundation." *Exploration Engineering: Rock, Soil Drilling and Tunneling*, **5(11)**: 51-53.