

الجمهورية الجزائرية الديمقراطية الشعبية

République Algérienne Démocratique et Populaire

وزارة التعليم العالي و البحث العلمي

Ministère de L'enseignement Supérieur et de la Recherche Scientifique

Université 20 Août 1955-Skikda

Faculté de Technologie

Département de Génie Civil

N° d'ordre D012124032D

Série.....



THESE

Présentée en vue de l'obtention du diplôme de

DOCTORAT en SCIENCES

En Génie Civil

Option : Géotechnique

APPLICATION DES METHODES D'OPTIMISATION DANS LE CALCUL DE STABILITE DES PENTES

Par :

KAMOUCHE Houda

Devant le Jury

Président	Marwa Feligha	M.C.A	Université 20 Aout 1955 Skikda
Rapporteur	REHAB BEKKOUCHE Souhila	Professeur	Université 20 Aout 1955 Skikda
Co-Encadreur	GOUDJIL Kamel	M.C.A	Université de Souk Ahras
Examineurs	Benchikh Massouda	M.C.A	Université 08 Mai 1945 Guelma
	Boukhatem Ghania	M.C.A	Université de Annaba

2024-2025

À la mémoire de mon père, et ma sœur Wafa et mon frère Ahmed

Que Dieu vous pardonne et ait pitié de vous ;

*À ma mère, la lumière de mes jours
que Dieu la récompense et la protège ;*

À mes frères et sœurs,

*Vous m'avez tout donné par votre présence pendant
les périodes dures comme celles faciles. Que le Dieu vous garde ;*

Merci infiniment

REMERCIEMENT

Avant tout je tiens à remercier Dieu miséricordieux qui nous a donné la capacité d'aller jusqu'au bout de nos rêves, et de nous avoir accordé la santé, la volonté et la patience d'achever ce travail.

Ma profonde gratitude s'adresse tout particulièrement à ma directrice de thèse

Pr. Rehab Bekkouche Souhila, qui m'a accordé sa confiance dans l'élaboration de cette thèse. Tout en suivant de près ma démarche scientifique, elle m'a fait partager son expérience enrichissante et m'a prodigué de précieux conseils et encouragements pour mener à bien ce travail. Je la remercie du fond du cœur et qu'elle veuille bien accepter encore une fois ma sincère reconnaissance et mon profond respect.

Je remercie également **Dr. Goudjil Kamel** qui m'a fait l'honneur de co-encadrer ce travail, je lui exprime toute ma gratitude pour la qualité de son encadrement, son soutien et sa confiance, pour m'avoir permis sur tous les plans, de mener à bien cette étude. Je suis toujours reconnaissante envers lui de m'avoir fait connaître le fascinant sujet de l'optimisation.

Je suis heureuse de pouvoir exprimer ici mes remerciements à chacun des membres du jury qui ont bien accepté d'évaluer ce travail, et pour l'honneur qu'ils m'ont fait, d'accepter d'être examinateurs de cette thèse.

Je tiens à remercier très vivement et respectueusement **Dr. Marwa Feligha** maître de conférences à l'université de Skikda, qui m'a fait l'honneur de présider le jury de thèse. Ensuite, j'exprime toute ma reconnaissance aux **Dr. Benchikh Massouda**, maître de conférences à l'université de Guelma et **Dr. Boukhatem Ghania**, maître de conférences à l'université de Annaba pour l'honneur qu'elles m'ont fait d'accepter d'être examinateurs de cette thèse.

Je suis profondément reconnaissante aussi envers **Dr. Benayoun Fadila**, pour la collaboration en termes de recherche, ses conseils en matière de recherche ont été toujours précieux.

Enfin, je tiens à adresser mes sincères remerciements ainsi que ma gratitude la plus dévouée à tous ceux qui m'ont aidée de près ou de loin pour réaliser ce travail de recherche

Résumé

Cette étude vise à évaluer l'influence des caractéristiques mécaniques du sol (cohésion, angle de frottement, module d'Young) et d'une caractéristique géométrique (volume du remblai) et de l'accouplement sur la stabilité des talus, notamment sur le facteur de sécurité et la surface de glissement.

Une analyse numérique approfondie a été menée à l'aide du logiciel Plaxis 2D. Afin d'optimiser la conception du modèle, une méthodologie basée sur la planification d'expériences (DOE) a été mise en œuvre, combinant les approches de Taguchi et des surfaces de réponse (RSM). Cette démarche a permis d'identifier la combinaison optimale des paramètres influant sur la stabilité du talus.

Parallèlement, des modèles d'apprentissage automatique, tels que l'Extreme Gradient Boosting (XGBoost), le Random Forest (RF) et les réseaux de neurones artificiels (RNA), ont été développés pour prédire le facteur de sécurité et caractériser la surface de glissement. Les performances de ces modèles ont été évaluées à l'aide de divers indices de performance et comparées aux résultats de l'analyse numérique.

Les résultats obtenus montrent que les caractéristiques mécaniques du sol ont un impact significatif sur la stabilité des talus. De plus, les modèles d'apprentissage automatique développés ont démontré d'excellentes capacités de prédiction, offrant ainsi un outil puissant pour l'évaluation et la conception des ouvrages géotechniques.

Mots clés : Pente, Facteur de sécurité, Plaxis 2D, modélisation, optimisation. MINITAB 19, l'intelligence artificielle.

Abstract

This study aims to assess the influence of soil mechanical properties (cohesion, friction angle, Young's modulus) and the geometric characteristic (fill volume) and coupling on the stability of slopes, particularly on the safety factor and slip surface.

An in-depth numerical analysis was conducted using the Plaxis 2D software. To optimize the model design, a methodology based on Design of Experiments (DOE) was implemented, combining the Taguchi and Response Surface Methodology (RSM) approaches. This approach allowed for the identification of the optimal combination of parameters influencing slope stability.

Concurrently, machine learning models such as Extreme Gradient Boosting (XGBoost), Random Forest (RF), and Artificial neural networks (RNA) have been developed to predict the safety factor and characterize the slip surface. The performance of these models has been evaluated using various performance metrics and compared to the results of the numerical analysis.

The results obtained show that the mechanical characteristics of the soil have a significant impact on the stability of slopes. Furthermore, the developed machine learning models have demonstrated excellent predictive capabilities, thus providing a powerful tool for the evaluation and design of geotechnical structures.

Keywords: Slope, Safety factor, Plaxis 2D, Modeling, Optimization, MINITAB 19, Artificial intelligence.

ملخص

تهدف هذه الدراسة إلى تقييم تأثير الخصائص الميكانيكية للتربة (التماسك، زاوية الاحتكاك، معامل يونج) والخاصية الهندسية (حجم السد) والتزاوج على ثبات المنحدرات، وخاصة على عامل الأمان وسطح الانزلاق وذلك بإجراء تحليل عددي متعمق باستخدام برنامج Plaxis 2D. لتحسين تصميم النموذج، تم تنفيذ المنهجية المستندة إلى تصميم التجارب (DOE)، والتي تجمع بين نهج تاغوتشي (Taguchi) ومنطقة سطح لاستجابة (RSM). حيث جعل هذا النهج من الممكن تحديد المجموعة المثالية من المعلمات التي تؤثر على استقرار المنحدر.

في الوقت نفسه، تم تطوير نماذج التعلم الآلي، مثل (XGBoost) Extreme Gradient Boosting، و (Random Forest (RF)، والشبكات العصبية الاصطناعية (RNA)، للتنبؤ بعامل الأمان وتحديد سطح الانزلاق. ثم تقييم أداء هذه النماذج باستخدام مؤشرات الأداء المختلفة ومقارنتها بنتائج التحليل العددي. أظهرت النتائج المتحصل عليها أن الخصائص الميكانيكية للتربة لها تأثير كبير على ثبات المنحدرات. علاوة على ذلك، أظهرت نماذج التعلم الآلي المطورة قدرات تنبؤية ممتازة، مما يوفر أداة قوية لتقييم وتصميم الهياكل الجيوتقنية.

الكلمات المفتاحية: الانحدار، عامل الأمان، Plaxis 2D، النمذجة، التحسين. Minitab 2019 والذكاء الاصطناعي.

Tables Des Matières

Table des matières

REMERCIEMENT	II
Résumé	IV
Tables Des Matières	VII
Liste des Figures	XI
Liste des Tableaux	XIV
Liste des Acronymes	XV
Liste des Notations	XVII
Introduction Générale	1
Chapitre I État de l'Art sur l'Optimisation Géotechnique et L'Apprentissage Automatique en Géotechnique	
I.1 Introduction	6
I. 2 Etat de l'art sur l'optimisation en Géotechnique	6
I. 3 Aperçu sur l'application des techniques d'intelligence artificielle (IA).....	15
I. 4 Conclusion.....	18
Chapitre II Méthodes d'Optimisation en Géotechnique	
II.1 Introduction	21
II.2 Méthodes d'optimisation utilisées en géotechnique.....	22
II.3 La méthode des plans d'expériences (DOE).....	23
II. 3. 1 Contexte et méthodologie des plans d'expériences.....	23
II. 3. 2 La conception d'un plan d'expérience.....	25
II. 3. 3 Avantages des plans d'expérience.....	25
II. 4 La méthodologie des surfaces de réponse (RMS).....	26
II. 4. 1 Les principes généraux	26
II. 4. 2 Étapes de la méthodologie de surface de réponse.....	27
II. 4. 2. 1 Planification expérimentale.....	28
II. 4. 2. 2 Modélisation	29

Tables des Matières

II. 4. 2. 3 Validation des modèles	29
II. 4. 3 La RSM pour l'optimisation en ingénierie	31
II. 4. 3. 1 Méthode graphique	31
II. 4. 3. 2 Méthodes numériques	31
II. 5 La méthode de Taguchi	32
II. 5. 1 Méthodologie de la méthode Taguchi	32
II. 5. 1. 1 Planification.....	32
II. 5. 1. 2 Réalisation	33
II. 5. 1. 3 Analyse.....	33
II. 5. 1. 4 Validation	33
II. 5. 2 La notion d'orthogonalité.....	34
II. 5. 3 Le rapport Signal/Bruit	35
II. 5. 4 Avantages et limites des plans d'expériences de Taguchi.....	37
II. 5. 5 Application de la méthode Taguchi.....	38
II. 5. 6 La méthode de Taguchi et l'analyse de variance (ANOVA).....	39
II. 6 Conclusion.....	40

Chapitre III Généralités sur l'Apprentissage Automatique

III.1 Introduction.....	42
III.2 Définition de l'intelligence artificielle	42
III. 2. 1 Sous-domaines de l'intelligence artificielle	43
III. 2. 1. 1 Apprentissage automatique	43
III. 2. 1. 2 Deep Learning	43
III. 3 Définition de l'apprentissage automatique (ML)	45
III. 4 La renaissance de l'apprentissage automatique	45
III. 5 Catégories de l'apprentissage automatique (Machine Learning)	46
III.5.1 Apprentissage supervisé	47
III. 5. 1. 1 La classification.....	48
III. 5. 1. 2 La régression	49
III. 5. 2 Apprentissage non-supervisé	49

Tables des Matières

III. 5. 2. 1 Le regroupement.....	50
III. 5. 2. 2 Réduction de la dimensionnalité	50
III. 5. 3 Apprentissage par renforcement	51
III. 6 Algorithmes d'apprentissage supervisé.....	51
III. 6. 1 Régression linéaire	51
III. 6. 1. 1 Régression linéaire simple	51
III. 6. 1. 2 Régression linéaire multiple	53
III. 7 Flux de travail d'apprentissage automatique.....	54
III. 8 Les modèles d'apprentissage automatique	55
III. 8. 1 Les apprentissage d'ensembles	55
III. 8. 1. 1 Concepts clés.....	56
III. 8. 2 Types d'apprentissage d'ensemble.....	56
III. 8. 2. 1 Le Bagging (Bootstrap Aggregating)	56
III. 8. 2. 2 Le Boosting	57
III. 8. 2. 3 L'Empilement.....	58
III. 9 Extreme Gradient Boosting (XGBoost)	59
III. 9. 1 Flux de travail de XGBoost	59
III. 9. 2 Principales caractéristiques de XGBoost.....	61
III. 10 Les Random Forest (RF)	61
III. 10. 1 Flux de travail de Random Forest	62
III. 10. 2 Principales caractéristiques de la forêt aléatoire	63
III. 11 Les réseaux de neurones	65
III. 11. 1 Les connexions entre les neurones	65
III. 11. 2 Les réseaux de neurones artificiels.....	66
III. 11. 3 Architectures de réseaux de neurones Artificiels.....	68
III. 11. 3. 1 Réseaux statique (non bouclés).....	68
III. 11. 3. 2 Réseaux dynamique (bouclés).....	69
III. 11. 4 Types des réseaux de neurones artificiels (RNA).....	70
III. 11. 4. 1 Perceptron	70

Tables des Matières

III. 11. 4. 2 Réseaux de neurones à propagation avant.....	70
III. 11. 4. 3 Réseaux de neurones récurrents (RNN)	71
III. 11. 4. 4 Réseaux de neurones convolutifs (CNN)	73
III. 11. 5 Flux de travail d'un réseau de neurones.....	73
III. 11. 6 Principales caractéristiques d'un réseau de neurones	75
III.12 Conclusion	77

Chapitre IV Position du problème et Méthodologie de calcul

IV.1 Introduction.....	79
IV.2 Reconnaissance du site.....	80
IV.3 Méthodologie de L'optimisation.....	83
IV. 3. 1 Modélisation Numérique	84
IV. 3. 2 Application des Méthodes d'Optimisation.....	85
IV. 3. 2. 1 la Méthode de Taguchi	85
IV. 3. 2. 2 Validation des résultats d'analyse de Taguchi avec ANOVA.....	94
IV. 3. 3 Application de la méthode des surfaces de réponses (RSM)	97
IV. 3. 3. 1 Résultats et discussions	98
IV. 3. 4 Application des Méthodes d'intelligence artificielles (l'Apprentissage Automatique)	105
III. 3. 4. 1 Résultats de la modélisation	106
IV. 3. 4. 2 Développement des modèles Extreme gradient boosting et Random Forest.....	109
IV. 3. 4. 3 la Méthode XGBoost (Extreme Gradient Boosting).....	113
IV. 3. 4. 4 la Méthode du Random Forest (RF).....	116
IV. 3. 4. 5 Réseau de neurones artificiels (RNN).....	118
IV. 4 Conclusion	121
Conclusions Générales et Perspectives	123
Références	126

Liste des Figures

II.1 Schéma plan d'expérience (Dounane, N 2021)	24
II.2 Conception Box-Behnken à trois facteurs(Abderrahim, Z., Hachemi,A 2019)	27
II.3 Étapes impliquées dans la conception de Box-Behnken (Benayoun, F 2021)	28
II.4 Représentation schématique de la méthodologie Taguchi (Dounane, N 2021).....	34
II.5 Illustration de comparaison de l'approche de Taguchi et l'approche classique (Dounane, N 2021).....	38
III.1 Sous-domaines de l'intelligence artificielle (Djelailia, D 2024).....	44
III.2 Catégories d'apprentissage automatique	47
III.3 Régression linéaire	53
III.4 Régression linéaire multiple	54
III.5 Flux de travail de l'étude sur l'apprentissage automatique (Mitchell, T. M 1997)	55
III.6 La technique de bagging (Dietterich, T. G 2000)	57
III.7 Approche d'ensemble séquentielle (Dietterich, T. G 2000)	58
III.8 Architecture d'empilement (Dietterich, T. G 2000).....	59
III.9 Flux de travail de l'algorithme XGBoost(Chen, T., & Guestrin, C 2016)	61
III.10 Algorithme de Random Forest (Breiman, L 2001)	63
III.11 Schéma d'un Neurone artificielle (Bouguerra, A., & Rouane.S 2019).....	67
III. 12 Un réseau de neurone non bouclé bouclé (Bouguerra, A., & Rouane.S 2019)...	69
III.13 Un réseau de neurone bouclé (Bouguerra, A., & Rouane.S 2019).....	70
III. 14 Un perceptron multicouche contenant trois couches.....	71
III.15 Une couche RNN simple à trois entrée et deux sorties. Les connexions récurrentes notées en rouge	72
III.16 Architecture standard d'un réseau de neurone à convolution CNN	73
IV.1 Situation général du site	81
IV.2 Situation détaillée du site du glissement	82
IV.3 Colonne stratigraphique du sédiment formations qui constituent la pente	82

Liste des Figures

IV.4 Géométrie du Talus	83
IV.5 Maillage par éléments finis du modèle étudié.....	85
IV.6 Courbes des effets principaux pour les rapports S / N.....	89
IV.7 Graphique des effets principaux pour les moyennes	90
IV.8 Diagramme d'interaction pour les rapports S / N	92
IV.9 Diagramme d'interaction pour les moyennes	93
IV.10 Droite de Henry pour les rapports S / N.....	95
IV.11 Valeurs Résiduels par rapport aux valeurs ajustées.....	96
IV.12 Résidus par rapport à l'ordre des données	96
IV.13 Effets principaux	99
IV.14 Diagramme de Pareto	100
IV.15 Graphiques normaux pour effets standardisés.....	101
IV.16 Lignes de contour.....	102
IV.17. Courbes de surface de réponse F_s pour une pente stabilisée avec des échantillons à un paramètre constant de : (a) 7 750 kPa d' E_{ref} , (b) 27,5 kPa de cohésion et (c) 35° d'angle de frottement	103
IV.18 Optimisation.....	105
IV.19 Bibliothèques utilisées dans les modèle XGBoost et RF	109
IV.20 Matrice de corrélation de cinq variables d'entrée et d'une variable de sortie.....	111
IV.21 Pair plot des différents paramètres de la base de données	112
IV.22 Les valeurs cibles du facteur de sécurité par rapport aux valeurs prédites de l'entraînement définies à l'aide du modèle proposé (XGBoost)	115
IV.23 Les valeurs réelles du facteur de sécurité par rapport aux valeurs prédites des tests effectués à l'aide du modèle proposé (XGBoost).....	115
IV.24 Les valeurs cibles du facteur de sécurité par rapport aux valeurs prédites de l'entraînement définies à l'aide du modèle proposé (RF)	117

Liste des Figures

IV.25 Les valeurs réelles du facteur de sécurité par rapport aux valeurs prédites des tests effectués à l'aide du modèle proposé (RF)	117
IV.26 Bibliothèques utilisées dans le modèle RNA	118
IV.27 Présentation du modèle RNA (modèle récapitulatif)	119
IV.28 Les valeurs cibles du facteur de sécurité par rapport aux valeurs prédites de l'entraînement définies à l'aide du modèle proposé (RNA)	120
IV.29 Les valeurs réelles du facteur de sécurité par rapport aux valeurs prédites des tests effectués à l'aide du modèle proposé (RNA)	120

Liste des Tableaux

IV.1 Propriétés des couches de sol	83
IV.2 Paramètres d'entrée et leurs niveaux	86
IV.3 Matrice orthogonale standard L27 de Taguchi.....	86
IV.4 Réponses mesurées et rapports S/N pour le model principale	88
IV.5 Réponses pour le rapport signal /bruit « plus petit est mieux»	91
IV.6 Réponses pour les moyennes.....	91
IV.7 Valeurs optimales.....	92
IV.8 Résultats de l'analyse de variance ANOVA.....	94
IV.9 Paramètres et plages pour l'analyse du talus.....	97
IV.10 Résultats expérimentaux selon un design Box-Behnken	98
IV.11 Paramètres et niveaux sélectionnés.....	106
IV.12 Facteurs de sécurité pour les différents paramètres	106
IV.13 Résumé de l'ensemble de données	110
IV.14 Les données après normalisation	111
IV.15 Les valeurs des mesures de performance (XGBoost).....	116
IV.16 Les valeurs des mesures de performance (RF).....	116
IV.17 Les valeurs des mesures de performance (RNA)	119

Liste des Acronymes

SS : Surface de glissement

FEM : Méthodes des élément finis

FDM : Méthodes des différences finies

DOE : Plan d'expérience (design of experiment)

GA : Algorithmes génétiques

PSO : Algorithmes d'optimisation par essaim de particules (particle swarm optimization)

ACO : Optimisation par colonie de fourmis (Ant Colony Optimization)

BCO : Algorithme d'optimisation des colonies d'abeilles

RNA : Réseaux de neurones artificiels

RSM : Méthode de surface de repense (response of surface methodology)

ANOVA : Analyse des variances (Analysis of variance)

BBD : Les plans Box-Behnken

MGA : Algorithme génétique modifié

SVM : Machine à vecteurs de support

ELM : Machine d'apprentissage extrême (Extreme Learning Machine)

WOA : Algorithme d'optimisation des baleines

SA : Recuit simulé (Simulated Annealing)

IWOA : Algorithme amélioré d'optimisation des baleines

IA : Intelligence artificielle

AdaBoost: Boosting adaptative (Adaptive Boosting,)

MCS : Simulation de Monte Carlo

BeeSVC : Vecteurs de support optimisé pour les colonies d'abeilles

GP : Processus gaussiens

Liste des Acronymes et des Notations

ML : Apprentissages automatique (Machine learning)

FA : Algorithme de luciole

GBM : Machine d'amplification de gradient (Gradient Boosting Machine)

XGBoost : Augmentation extrême du gradient (Extreme Gradient Boosting)

RF : Forêt aléatoire (Random Forest)

GBRT : Arbre de régression boosté par gradient

MLP : Réseau de neurone multicouches (MultiLayer Perceptron)

DP : Apprentissage profond (Deep learning)

ReLu : Unité linéaire rectifiée (rectified linear unit)

MNN : Réseau de neurones à mémoires

DTRNN : Réseau neuronal récurrent à temps discret

RNN : Réseaux de neurones convolutifs récurrents

CNN : Réseaux de neurones convolutifs

K-Fold : Validation croisée

Liste des Notations

C (kN/m²) : Cohésion

φ (deg) : Angle de frottement

E_{ref} (kN/m²) : Module d'Young

V (m³) : Volume du remblai

γ (kN/m³) : Poids volumique

FS : Coefficient de sécurité

y : Réponse

x_i : Facteurs

β_0 : Coefficient constant de modèle

β_i : Coefficient $i^{i\text{ème}}$ linéaire du paramètre d'entrée x_i

β_{ii} : Coefficient $i^{i\text{ème}}$ quadratique du paramètre d'entrée x_i

β_{ij} : Coefficient d'interaction entre les paramètres d'entrée x_i et x_j

ε : Erreur du modèle

R^2 : Coefficient de détermination

R^2_{adj} : Mesure améliorée de R^2

RMSE : Erreur quadratique moyenne

SS_T : Partition de l'erreur totale

SS_R : Erreur accidentelle

SS_E : Erreur systématique

\hat{y} : Réponses moyenne

OA : Tableau orthogonal

S/N : Rapport signal sur bruit

n : Nombre de répétitions pour une combinaison expérimentale

y_i : Valeur de performance de la $i^{i\text{ème}}$ expérience

Liste des Acronymes et des Notations

y_0 : Valeur nominale souhaitées.

MAPE : Erreur moyenne en pourcentage absolu

COV : Coefficient de variation

EQM : Erreur quadratique moyenne

REQM : Racine de l'erreur quadratique moyenne

MBE : Erreur de biais moyenne

L_1 et L_2 : Coefficient de régularisation

b_j : Seuil

φ : Fonction d'activation

x_j^t : Entrées à l'instant t

y_j^t : Sorties à l'instant t

W_{ji} : Poids reliant les entrées à la sortie

$W_{jj'}$: Poids entre la sortie et l'entrée de la couche

\emptyset_{input} : Valeur d'entrée de l'angle de frottement interne

$\emptyset_{\text{reduced}}$: Valeur réduite de l'angle de frottement interne à la rupture

C_{input} : Valeur d'entrée de la cohésion

C_{reduced} : Valeur réduite de la cohésion à la rupture

DF : Degrés de liberté

Seq SS : Somme des carrés

F : Coefficient de probabilité

P : Facteur de contribution

Introduction Générale

Les caractéristiques des sols sont complexes et variables dans l'espace et dans le temps. De ce fait, les paramètres que l'on doit introduire dans les calculs géotechniques, sont souvent mal connus. De nombreux modèles constitutifs de sols existent pour représenter la plupart des comportements de sols réels, ces modèles approchés peuvent être utilisés avec une certaine confiance dans les calculs, à condition de bien choisir les valeurs des paramètres (Blondeau, F,1976). Les équations définissant le comportement des sols sont complexes et fortement non linéaires, ainsi que dans l'analyse des problèmes géotechniques comme l'analyse de la stabilité des talus, les équations à résoudre sont souvent non linéaires.

Pour pallier au problème sous cité, on utilise un principe d'analyse dans l'identification des paramètres du sol et/ou la résolution des équations d'analyse des problèmes géotechniques. Ce principe dans les problèmes complexes de la géotechnique est utilisé comme méthodes numériques directes, que nous l'appelons méthodes d'optimisation.

L'optimisation peut être définie comme l'art d'améliorer les choses, il est intéressant de noter que très souvent, l'optimisation ne nous permet pas simplement de faire quelque chose de mieux, mais elle peut également permettre de faire quelque chose que nous ne savions pas faire autrement.

Afin d'atteindre cet objectif et d'avoir la capacité d'appliquer l'optimisation à des problèmes du monde réel. Nous utilisons la puissance de l'ordinateur, en conjonction avec l'étude de différents aspects pratiques importants de l'optimisation. Pour ce faire, nous utilisons un outil de modélisation et de codage informatique puissant, facile à utiliser et largement appliqué dans l'ingénierie et dans d'autres domaines. Le MATLAB est un excellent choix d'outils, il est devenu l'outil le plus populaire pour la modélisation informatique dans le monde (Yin, Z.Y., and Jin, Y.F,2019)

Introduction Générale

Alors le problème d'optimisation est défini comme la recherche de la meilleure solution à partir de la solution réalisable dans un bain qui contient toutes les solutions. Dans de nombreux problèmes d'ingénierie, la solution optimale peut être la valeur minimale ou maximale de la fonction objective du problème. Parfois, le problème d'optimisation peut avoir plusieurs fonctions objectives et plusieurs solutions.

De nos jours, une croissance et développement dans le domaine d'optimisation en génie civil en particulier, la géotechnique tel que la modélisation des ouvrages et la prédiction de la réponse structurelle est plus précise que dans les décennies passées (Leps, M ,2005). Plusieurs nouveaux défis que nous voulons découvrir, et aussi plusieurs problèmes.

L'objectif principal de cette thèse est d'optimiser la stabilité des talus en s'appuyant sur des méthodes statistiques et d'apprentissage automatique. Dans un premier temps, nous avons utilisé la méthode de Taguchi et la méthode des surfaces de réponse pour identifier les paramètres géotechniques les plus influents sur la stabilité des talus et déterminer leur combinaison optimale. Parallèlement, nous avons exploré l'application de l'intelligence artificielle, en particulier de l'apprentissage automatique, s'est imposé comme un outil puissant pour résoudre des problèmes géotechniques complexes, tels que les réseaux de neurones artificiels, inspirés du fonctionnement du cerveau humain, Ils ont initialement conçu pour imiter le processus d'apprentissage biologique, ont évolué pour s'appuyer sur des fondements statistiques solides. Ils permettent ainsi de reproduire la capacité d'adaptation des êtres humains face à de nouvelles situations.

Également parmi les apprentissages automatiques XGBoost, Random Forest, tous ces modèles ont la capacité de traiter de grandes quantités de données et d'apprendre des corrélations complexes entre les variables, offrant ainsi un potentiel élevé pour améliorer la précision des prédictions.

Les modèles d'apprentissage automatique, telles que XGBoost, Random Forest et les réseaux de neurones artificiels, offrent une grande flexibilité pour s'adapter à des jeux de données variés et améliorer ainsi la précision des prédictions. Ces techniques sont de plus en plus considérées comme des outils incontournables pour l'analyse de la stabilité des pentes.

Dans cette étude, nous avons développé un modèle numérique pour simuler le comportement des pentes. Nous nous sommes particulièrement intéressés à l'influence de quatre paramètres géotechniques clés : la cohésion (C), l'angle de frottement (ϕ), le module d'Young de référence (Eref) et le volume de remblai (V). Ces paramètres, identifiés comme étant les plus influents sur la stabilité des pentes, ont été utilisés comme variables d'entrée pour estimer le facteur de sécurité (FS).

Afin d'atteindre les sous-objectifs énumérés précédemment, la recherche réalisée se compose de deux phases suivantes :

Phase 1 : est consacré au développement d'une méthode d'optimisation par Taguchi et la méthode de surface de repense (RSM) pour l'estimation des paramètres mécaniques en se basant sur des mesures de déformations. Le problème donné doit tout d'abord être modélisé numériquement par un calcul éléments finis. En fonction des paramètres supposés au modèle, une réponse numérique est calculée.

Phase 2 : l'acquisition des données recueillies lors de modélisation numérique par un calcul éléments finis constitue une base des données de l'apprentissage automatique (ML). Dans le but d'estimer l'efficience et l'efficacité de la méthode présentée.

Le corps du document de la thèse est structuré en quatre chapitres illustrés comme suit : Le chapitre I dresse un état de l'art des techniques d'optimisations et de l'intelligence artificielle (IA) dans le domaine de génie civil en générale et les problèmes géotechniques en particulier. Parmi eux une attention particulière a été portée sur les méthodes dites évolutionnistes et qui ont connu depuis le début des années soixante une

Introduction Générale

croissance exceptionnelle. En plus les statistiques ont évolué dans différentes directions, parmi lesquelles les plans d'expériences et l'intelligence artificielle.

Le chapitre II illustre l'intérêt des techniques d'optimisation, ont particulièrement la méthode des plans d'expériences compris la méthode de Taguchi et la méthode de surface de repense (RSM).

Le chapitre III est consacré à une étude bibliographique sur les méthodes de l'intelligence artificielle (IA) en accordant une importance particulière premièrement à l'apprentissage automatique (ML) plus précisément les méthodes d'ensemble et deuxièmement aux réseaux de neurones artificiels (RNA).

Dans le chapitre IV, on aborde le processus d'optimisation des paramètres résultant de la modélisation numérique du modèle géométrique du pente, en utilisant le logiciel (PLAXIS 2D), où chaque méthode d'optimisation a été testée et appliquée de façon classique à partir de fonctions mathématiques, deux méthodes d'optimisation ont été appliquées : Taguchi et la méthode de surface de réponse.

Pour les applications des méthodes d'intelligence artificielle (IA) nous explorerons à travers XGBoost (Extreme Gradient Boosting), la forêt aléatoire (RF) et de plus les Réseaux de neurones artificiels (RNA). De tel façon d'intégrer l'analyse des données numériques dans un système d'évaluation de la sécurité et de la stabilité des pentes basé sur ces techniques est de trouver la combinaison optimale de facteurs d'entrée de pente. Nous conclurons le travail par une discussion des résultats obtenus, des conclusions et des perspectives sur les travaux effectués et les travaux à venir

Chapitre I

État de l'Art sur l'Optimisation Géotechnique et L'Apprentissage Automatique en Géotechnique

I.1 Introduction

Les problèmes géotechniques sont complexes, dont les équations qui lient les paramètres du sol sont généralement irréversibles et non linéaires. Des incertitudes sur ces paramètres, qui nécessite une bonne compréhension de la manière que les différents paramètres influent et en plus la sélection des méthodes appropriées pour les analyses.

Les ingénieurs géotechniciens cherchent toujours à développer des nouvelles approches, moins chers, de courte durée et avec une grande précision, afin de résoudre les problèmes complexes rencontrés. Tels que, la conception optimale des structures de soutènement et des fondations peu profondes, l'analyse automatisée de la stabilité des pentes...etc.

À cet effet, dans les années soixante sont apparues les premières recherches dans les problèmes d'optimisation, qui présente un grand intérêt dans la résolution des problèmes complexes. Elle montre son efficacité dans le domaine de la géotechnique et surtout dans le calcul de la stabilité des pentes.

En raison de la complexité du système physique lui-même et la difficulté impliquée dans la détermination les données d'entrée nécessaires associées aux paramètres géotechniques. L'intelligence artificiel est apparue de nos jours comme un outil avancé pour résoudre ces problèmes et avoir de meilleurs résultats.

I.2 Etat de l'art sur l'optimisation en Géotechnique

Dans ce chapitre, nous avons passé en revue plusieurs études utilisant les différentes techniques d'optimisation dans les multiples divisions de problèmes de l'ingénierie géotechnique (Dede et al, 2019), et particulièrement la stabilité des pentes.

L'analyse de la stabilité des pentes est toujours une question brûlante et un problème complexe dans le domaine de l'ingénierie géotechnique, qui a attiré l'attention de nombreux chercheurs en géotechnique. La plupart des manuels sur la mécanique des sols

incluent plusieurs méthodes d'analyse de la stabilité des pentes pour trouver une surface de glissement critique ou une configuration optimale (Benayoun, 2021).

Un examen détaillé des méthodes d'équilibre de l'analyse de la stabilité des pentes est présenté par (Duncan, 1996). Ces méthodes comprennent la méthode ordinaire des tranches en 1936, la méthode modifiée de Bishop 1955, la méthode de Morgenstern et Price 1965 et la méthode de Spencer 1967.

Ainsi, le calcul de variation par Baker et Gaber 1978, la méthode du simplexe par Nguyen 1985, la méthode des variables alternées par Celestino et Duncan 1981, méthode du gradient conjugué par Arai et Tagyo 1985, programmation dynamique par Baker 1980, ainsi que Yamagami et Jiang 1997, méthode du simplexe avec la méthode de descente la plus raide et la méthode Davidson-Fletcher-Powell de Chen et Shao 1988 et de nombreuses autres méthodes similaires.

Compte tenu des limites des méthodes conventionnelles mentionnées ci-dessus pour prédire la surface de glissement (sliding surface, SS). L'analyse de la stabilité des pentes est passée de calculs manuels fastidieux à des solutions informatiques. L'amélioration des outils d'analyse de la stabilité des pentes dans la plupart des cas, a amélioré la compréhension de l'ingénieur sur le problème de stabilité de pente. Ils ont utilisé les méthodes des élément finis [FEM] et des différences finies [FDM] avec un grand effet pour la détermination de la surface de glissement SS. Ces méthodes présentent plusieurs avantages : modéliser les pentes avec un très haut degré de réalisme (géométrie complexe, séquences de chargement, présence de matériau de renforcement, action de l'eau, lois de comportement des sols complexes...) et mieux visualiser des déformations des sols en place. Parmi ces travaux de recherche on cite :

Chapitre I État de l'Art sur l'Optimisation Géotechnique et L'Apprentissage Automatique en Géotechnique

- Fredlund et Krahn (1977) ont utilisé une comparaison des six méthodes de tranches couramment pour l'analyse de la stabilité des pentes. Une nouvelle dérivation pour la méthode Morgenstern – Price ont présenté et appeler la solution de « régression la mieux adaptée ».
- Zhou et Cheng (2013) ont présenté la méthode rigoureuse des colonnes d'équilibre limite, par laquelle les forces inter-colonnes sont prises en compte. La valeur du facteur de sécurité a obtenu à l'aide de la méthode des moindres carrés de Levenberg – Marquardt.
- Tsiamposi, Zdravkovic et Potts (2016) ont étudié l'influence de l'interaction sol-atmosphère sur la stabilité et la facilité d'entretien d'une pente creusée dans l'argile de Londres.
- Kokutse, Temgoua et Kavazović (2016) ont mené une analyse numérique à l'aide du logiciel PLAXIS 2D pour étudier l'influence de la végétation sur la stabilité des pentes.
- Zebarjadi, Kakaie et al (2018) utilisant la modélisation numérique pour évalue les effets de la prise en compte de la géométrie réelle, et des changements dans les paramètres géomécaniques, comme des effets des médias sur la stabilité globale de la pente d'une mine à ciel ouvert.
- Roul, Pradhan et al (2021) ont appliqué une enquête sur l'instabilité des pentes le long des pentes ferroviaires dans la chaîne de montagnes des Ghâts orientaux, Inde. Une étude comparative basée sur l'évaluation de la masse des pentes, la modélisation par éléments finis et les méthodes probabilistes.

Cependant, depuis peu ils ont rapporté avec succès la pertinence de l'optimisation dans le domaine de l'ingénierie géotechnique, elle est devenue de plus en plus importante. L'incapacité à résoudre les problèmes dans des situations particulières était de plus en plus appréciée, ce qui mettre les chercheurs à appliquer l'optimisation techniques à des

fins différentes : trouver la meilleure désinence qui concerne la géométrie, la forme, le poids et le coût ... etc.

Une revue de l'état de l'art sur l'application du divers algorithmes d'optimisation heuristique développés traitent de l'optimisation des discontinus difficiles. Dans différents types de problèmes géotechniques peut être trouvé dans les travaux suivants, ou les algorithmes les plus populaires incluent telles que le plan d'expérience (DOE), l'algorithmes génétiques (GA), l'optimisation par essaim de particules (PSO), l'algorithme d'optimisation des colonies de fourmis ACO, l'algorithme d'optimisation des colonies d'abeilles (BCO) Topologie et les réseaux de neurones artificiels (RNA) et le recuit simulé.

- Zangeneh, Azizian et al (2002) ont utilisé la méthode de surface de réponse (RSM) à l'analyse de déplacement de Newmark des pentes sous-marines, dont les facteurs les plus significatifs qui affectent le déplacement de pente de Newmark ont identifié et un modèle de recharge ont obtenu.
- Kiki et al (2006) ont rapporté la méthode de Taguchi pour analyser les résultats expérimentaux de la stabilisation d'une argile gonflante traitée par des solutions de cosse de néré.
- Karna et Sahai (2012) ont réalisé une approche basée sur la méthode Taguchi, dont le rapport signal- bruit (S/N) et l'analyse de variance (ANOVA) utilisé pour étudier les caractéristiques de performance par des paramètres de processus sur le processus d'usinage.
- Li L et Chu XS (2015) ont développé une approche de surfaces de réponse multiples pour approximer la fonction d'état limite pour la rupture de pente par des fonctions polynomiales du second ordre.
- Ranade et Thiagarajan (2017) ont comparé les plans Box-Behnken, Central-Composite, D et I-optimaux à l'aide d'outils statistiques. Des essais expérimentaux

pour tous les modèles ont été générés. Des réponses aléatoires uniformes ont été simulées pour tous les modèles.

- Güllü et Fedakar (2017) ont utilisé la méthodologie de surface de réponse (RSM), ils ont concentré principalement sur l'étude des quantités optimales de stabilisants (cendres de boues d'épuration (SSA) et fibres de polypropylène (PF)) et du temps de durcissement (CT) qui donnent la résistance maximale à la compression libre (UCS) pour la stabilisation d'un sable marginal (sable mal granulé).
- Khoshnevisan, Wang et Juang (2017) ont appliqué l'approche de conception géotechnique robuste RGD en introduisant une surface de réponse comme substitut au code informatique basé sur les éléments finis ou les différences finies pour analyser le système, et ont développé un algorithme rapide pour le processus d'optimisation.
- Kolivand et Rahmamejad (2018) ont étudié l'optimisation des paramètres de comportement du sol sur la base de la méthode de conception d'expérience (DOE).
- Lafifi, Rouaiguia et Boumazza (2019) ont étudié l'optimisation des paramètres géotechniques des sols par l'utilisation des plans d'expériences de Taguchi. Cette technique a utilisé, à travers la modélisation numérique par le logiciel en éléments finis Plaxis, de l'essai pressiométrique.
- Polat et Sayan (2019) ont menu suite à la caractérisation des cristaux préparés par différentes concentrations d'acide citrique, la méthodologie de surface de réponse couplée au design Box-Behnken comme outil statistique pour déterminer les effets
- des paramètres clés affectant le processus de précipitation (température, pH et concentration d'additifs).
- Benayoun, Boumezerane, Rehab et Fadel (2021) ont étudié l'effet des paramètres géométriques des clous sur l'analyse des murs cloués au sol et l'identification des facteurs qui affectent le plus leur stabilité et leur coût en utilisant la méthodologie de surface de réponse (RSM).

Chapitre I État de l'Art sur l'Optimisation Géotechnique et L'Apprentissage Automatique en Géotechnique

Dans les années 2000 plusieurs travaux utilisant les algorithmes génétiques pour traiter différents problèmes géotechniques :

- Goh (1999) a utilisé un algorithme génétique (AG) pour localiser la surface de glissement critique, et a constaté que l'AG pouvait identifier avec précision la surface de glissement critique qui correspond à la situation réelle.
- McCombie et Wilkinson (2002) ont appliqué un AG simple pour rechercher le facteur de sécurité minimum dans l'analyse de la stabilité des pentes.
- Zolfaghari et al (2005) ont développé un programme de localisation de surface de glissement critique basé sur un AG et la méthode Morgenstern-Price pour une pente homogène
- En étudié Tree genetic programming (TGP) la formulation de la résistance à la compression non confinée des sols meubles par Narendra et al (2006) et l'évaluation des déplacements latéraux induits par la liquéfaction ont été réalisé par Javadi et al (2006).
- Li et al (2010) ont développé une méthode de calcul du facteur de sécurité de pente minimum basée sur l'AG codé réel, et ont vérifié les résultats à travers de nombreux exemples.
- Mousavi et al (2011) ont proposé une génétique non linéaire des paramètres de résistance au cisaillement du sol.
- Nansheng, Bo et al (2015) ont créé un modèle analytique optimal et utilisé un algorithme génétique modifié (MGA) pour rechercher la surface de glissement des pentes des barrages en terre-enrochement.
- Yin, Jin et al (2017) ont utilisé une étude comparative des techniques d'optimisation (algorithmes génétiques, optimisation des essaims de particules et algorithme des colonies d'abeilles artificielles) pour identifier les paramètres du sol en génie géotechnique.

- Bhandary, Krishnamoorthy et Rao (2018) ont proposé une procédure permettant de déterminer le facteur de sécurité d'une pente, en utilisant la méthode des éléments finis en conjonction avec un algorithme génétique.
- Singh, Banka, et Verma (2019) ont comparé les performances des AG, des PSO et de l'optimisation basée sur la biogéographie (BBO) lorsqu'elles sont appliquées à l'emplacement critique de la surface de glissement problèmes.
- Benayoun, Boumezerane et Rehab (2021) ont réalisé une analyse par éléments finis à l'aide du logiciel Plaxis2D pour modéliser une coupe verticale renforcée par des clous. L'optimisation de l'effet de trois paramètres d'entrée sur la conception de la stabilité des murs est un élément clé de l'analyse. Ils ont comparé les résultats obtenus par trois techniques d'optimisation de la conception : le plan d'expérience de Taguchi (DOE), l'algorithme génétique (GA) et l'optimisation par essaim de particules (PSO).

La littérature révèle aussi que les RNA ont été utilisés pour un grand éventail de problèmes d'ingénierie géotechnique, comme c'est présenté dans les travaux de Shahin et al., 2001, 2002, 2004 ; Alavi et al., 2008, 2009a, 2010a, 2010b ; Alavi et Gandomi., 2011b).

- Ferentinou et Sakellariou (2007) ont travaillé sur l'outil d'intelligence informatique dans la prévision des performances des pentes dans des conditions statiques et dynamiques. Ils ont présenté les résultats obtenus en utilisant l'algorithme de rétro-propagation, la théorie des réseaux neuronaux bayésiens et les cartes auto-organisatrices de Kohonen.
- Cheng, Li et al (2007) ont appliqué six algorithmes d'optimisation heuristique à des pentes simples et compliqués pour illustreront l'importance des minima locaux dans l'analyse de minimisation globale.
- Li et Wang (2010) ont résolu deux modèles de prévision basés sur ANN et SVM, par la dérivation des principaux facteurs de stabilité des pentes.

- Erzin et al (2013) ont porté leur étude sur le développement des réseaux de neurones artificiels (RNA) et des modèles de régression multiple (MR) qui peuvent être utilisés pour estimer la valeur du facteur critique de sécurité (Fs) de pentes finies homogènes.
- Zaobao et al (2014) ont présenté une évaluation et une prédiction de la stabilité des pentes avec l'approche d'un réseau de neurones robustes rapides appelée (Extreme Learning Machine ELM).
- Qian, Chen et al (2019) ont appliqué des méthodes d'analyse de limite supérieure (UB) et inférieure (LB) par éléments finis (LA) pour étudier la stabilité inhomogène des pentes de sol. Afin de minimiser les erreurs de lecture manuelle lors de l'utilisation des solutions graphiques, un réseau de neurone artificiel (RNA) a été utilisé pour développer un outil d'évaluation de la stabilité pour les pentes étudiées.
- Ray, Kumar, Rai et al (2020) ont développé un modèle de réseau neuronal artificiel (RNA) pour évaluer le facteur de sécurité des pistes de Shivalik dans la région himalayenne
- Meng, Mattsson et Laue (2021) ont adopté et entraîné des réseaux de neurones artificiels pour prédire la stabilité des pentes et un programme SlopeLab ont développé avec une interface utilisateur graphique, pour réduire le nombre de variables.

Le PSO a été largement appliquée dans différents aspects de l'ingénierie géotechnique tels que l'analyse de la stabilité des pentes, l'ingénierie des fondations en pieux, la mécanique des roches et des sols, la conception des tunnels et d'espaces souterrains. En plus des applications susmentionnées. PSO est également utilisé comme algorithme d'apprentissage dans les réseaux de neurones artificiels (RNA) qui sont largement utilisés en génie géotechnique. Parmi ces applications.

- Kalatehjari, Hajihassaniet al (2012) ont développé et vérifié un code informatique de PSO pour trouver des SS dans des pentes de sol homogènes.

Chapitre I État de l'Art sur l'Optimisation Géotechnique et L'Apprentissage Automatique en Géotechnique

- Kalatehjari et al (2015) ont déterminé la surface de glissement critique des pentes par utilisation d'optimisation de l'essaim de particules PSO.
- Luo, Nguyen et al (2019) ont menu une nouvelle technique d'intelligence hybride basée sur une optimisation de l'algorithme cubiste par une méthode évolutive PSO, à savoir la technique PSO-CA pour prédire le facteur de sécurité (FS) dans la stabilité des pentes dans les mines à ciel ouvert.
- Himanshu et Burman (2019) ont développé un code MATLAB basé sur l'optimisation par essaim de particules (PSO) pour rechercher le SS et le FOS minimum associé des pentes en minimisant la fonction objective.
- Shinoda et Miyata (2019) ont adopté l'algorithme d'essaim de particules (PSO) pour localiser la surface de glissement critique d'une pente renforcée.
- Armaghani et al (2019) ont proposé deux modèles prédictifs précis et pratiques des paramètres de résistance au cisaillement du sol via des modèles hybrides basés sur un réseau neuronal artificiel, à savoir un algorithme génétique et une optimisation de l'essaim de particules pour prédire la cohésion du sol sableux combiné à la fibre.

Concernant les méthodes : algorithme d'optimisation des baleines (WOA) et algorithme de recuit simulé (SA) sont intègres dans l'application à l'étude géotechnique pour éliminer ces limitations.

- Chen (2007) a proposé une méthode de localisation de la surface de glissement critique basée sur un algorithme de recuit simulé (SA) et appliqué cette technique à certains grands projets à Hong Kong, Chine.
- Li, Wu et Luo (2020) ont développé une nouvelle méthode pour localiser la surface de glissement critique d'une pente de sol, par l'utilisation d'un algorithme amélioré d'optimisation des baleines (IWOA).

I. 3 Aperçu sur l'application des techniques d'intelligence artificielle (IA)

Le développement rapide des techniques d'intelligence artificielle (IA), y compris leur robuste capacité de prédiction et l'excellente capacité de généralisation ont permis progressivement de résoudre des problèmes d'ingénierie. Des applications de ces méthodes en génie géotechnique se trouve dans la section suivante :

- Freund et Schapire (1996) ont introduit un nouvel algorithme de « boosting » appelé AdaBoost pour réduire considérablement l'erreur de tout algorithme d'apprentissage qui génère systématiquement des classificateurs et décrivant les expériences, mené pour évaluer les performances d'AdaBoost sur des problèmes d'apprentissage réels.
- Breiman (2001) a montré que le regroupement pouvait effectivement réduire la variance des prédicteurs de régression, tout en laissant le biais relativement inchangé. Il a conclu une nouvelle forme d'ensachage appelé l'ensachage itéré efficace pour réduire à la fois les biais et la variance.
- Friedman (2001) a montré que l'augmentation du gradient des arbres de régression produit des procédures compétitives, très robustes et interprétables pour la régression et la classification, particulièrement appropriées pour l'extraction de données moins que propres.
- Friedman (2002) a conclu que à chaque itération, un sous-échantillon des données d'entraînement est tiré au hasard (sans remplacement) de l'ensemble complet de données d'entraînement et utilisé à la place de l'échantillon complet pour ajuster l'apprenant de base et calculer la mise à jour du modèle pour l'itération en cours. Cette approche aléatoire augmente également la robustesse face à la surcapacité de l'apprenant de base.

On conclure que Friedman (2001,2002) se concentre davantage sur le développement de l'algorithme de la descente de gradient lui-même, où ils proposent ce que l'on appelle le boosting de gradient glouton.

- Zhao (2007) a présenté une nouvelle méthodologie d'analyse de la fiabilité des pentes en intégrant les technologies de mise à jour de la machine à vecteurs de support (SVM) et de la simulation de Monte Carlo (MCS).
- Pradhan et Lee (2010) ont présenté une analyse de susceptibilité aux glissements de terrain dans la région de la vallée de Klang, en Malaisie, à l'aide d'un modèle de réseau de neurones artificiels à rétropropagation et leur comparaison avec le rapport de fréquence et la modélisation de régression logistique bivariée.
- Cheng et Hoang (2015) ont proposé un nouveau classificateur de vecteurs de support optimisé pour les colonies d'abeilles (BeeSVC) pour prédire les effondrements de pente induits par les typhons.
- Kang, Xu et al (2016) ont appliqué un modèle de substitution basé sur une nouvelle technique d'apprentissage automatique v-support vector machine (v-SVM) pour l'analyse de la fiabilité du système de pente, des algorithmes d'optimisation globale d'essaim de particules et un algorithme de colonie d'abeilles artificielles ont été adopté pour sélectionner les hyper-paramètres du modèle v-SVM.
- Gerrard, Kang et al (2017) ont présenté une méthode d'évaluation de la stabilité des pentes basée sur les processus gaussiens (GP), qui est une technique d'apprentissage automatique populaire pour la modélisation de systèmes non linéaires. La fonction de covariance est l'une des parties les plus critiques de la modélisation des GP.
- Qi et Tang (2018) ont proposé et comparé six approches intégrées d'IA pour la prédiction de la stabilité des pentes. Ils ont utilisé des algorithmes ML pour la modélisation des relations et l'algorithme de luciole (FA) pour le réglage des hyper-paramètres. Six algorithmes ML, dont la régression logistique, l'arbre de décision, la

forêt aléatoire, la machine d'amplification de gradient, la machine à vecteurs de support et le réseau neuronal perceptron multicouche.

- Zhou, Li, Yang et al (2019) ont présenté une nouvelle méthode de prédiction qui utilise la méthode GBM (Gradient Boosting Machine) pour analyser la stabilité des pentes. Leur modèle basé sur GBM est développé par le logiciel R environnement disponible gratuitement, formé et testé.
- Emrehan (2020) a produit une carte de susceptibilité aux glissements de terrain du district d'Ayancik de la province de Sinop, situé dans la région de la mer Noire en Turquie, en utilisant trois méthodes d'ensemble basées sur des arbres de régression, notamment les machines à amplification de gradient (GBM), l'amplification de gradient extrême (XGBoost) et forêt aléatoire (RF).
- Wang, Wu, Tang et al (2020) ont développé une approche efficace d'analyse de fiabilité basée sur l'amplification du gradient extrême (XGBoost), pour évaluer la probabilité de rupture de la pente d'un barrage en terre. L'approche proposée est illustrée à l'aide d'un cas pratique adapté du barrage en terre d'Ashigong.
- Liu, Gilbert, Cepeda et al (2021) ont présenté trois algorithmes d'apprentissage automatique (ML), la forêt aléatoire (RF), l'arbre de régression boosté par gradient (GBRT) et le réseau neuronal MultiLayer Perceptron (MLP), et les applique à la modélisation spatiale des eaux peu profondes. Glissements de terrain près de Kvam en Norvège.
- Bharti, Mishra et al (2021) ont appliqué des nouvelles techniques de classification de la stabilité des pentes (SS), à savoir la forêt aléatoire, la machine d'amplification de gradient, l'amplification de gradient extrême, les arbres boostés et les arbres de classification et de régression. Pour prédire la stabilité ou l'instabilité de la pente.
- Pham et al (2021) ont menu deux techniques d'ensemble importantes, l'apprentissage parallèle et l'apprentissage séquentiel pour mettre en œuvre les classificateurs d'ensemble. De plus, à titre de comparaison, huit algorithmes d'apprentissage

automatique polyvalents ont été utilisés pour formuler les modèles de classification à apprentissage unique.

- Dhruva, Arunava et al (2022) ont utilisé plusieurs paramètres physiques et géométriques des pentes pour prédire le facteur de sécurité d'une pente de sol résiduel naturel et d'une pente de décharge de mort-terrain artificielle. Cependant, plusieurs algorithmes basés sur l'apprentissage automatique comme Support Vector Regressor, Artificial Neural Network, Random Forest, Gradient Boosting et Extreme Gradient Boost ont été sélectionnés pour la modélisation. Les résultats dérivés des modèles ont été comparés à ceux obtenus à partir de l'analyse numérique.
- Quanpeng (2022) a analysé tout d'abord l'algorithme d'apprentissage automatique et son processus de modélisation. Ensuite, l'algorithme XGBoost est utilisé pour la modélisation et l'algorithme génétique est utilisé pour l'optimisation du modèle. Sur la base du modèle optimisé pour évaluer la stabilité des pentes du comté de Ningnan.

I. 4 Conclusion

Dans ce chapitre, nous avons exploré plusieurs travaux de recherche menés par des différentes techniques d'optimisation. En particulier les problèmes de stabilité des pentes. Après cette rapide présentation d'application de différentes techniques d'optimisation, on s'aperçoit que dans le large panorama des méthodes d'optimisation adaptées aux problèmes d'optimisation géotechniques nous avons le choix d'utiliser la technique la plus adapté à notre problème et la disponibilité des données nécessaires pour résoudre un problème d'optimisation.

Cependant, les avantages et les inconvénients de ces techniques d'optimisation sont rarement synthétisés et comparés de manière systémique pour un même problème géotechnique. Par conséquent, une revue et une étude comparative sont nécessaires pour une bonne compréhension des différences entre les différentes techniques, ce qui peut

Chapitre I État de l'Art sur l'Optimisation Géotechnique et L'Apprentissage Automatique en Géotechnique

aider à sélectionner la méthode d'optimisation appropriée pour résoudre les problèmes d'ingénierie géotechnique.

Pour réduire les incertitudes et l'ambiguïté des modèles utilisés. Les chercheurs ont mis au point les techniques d'intelligence artificielle (IA) qu'est apparue comme un outil avancé pour résoudre des problèmes géotechniques complexes.

Chapitre II

Méthodes d'Optimisation en Géotechnique

II.1 Introduction

L'optimisation est un paradigme important avec un large éventail d'applications. Dans presque tous les domaines de l'ingénierie et de l'industrie, on essaie d'optimiser quelque chose, que ce soit pour minimiser les coûts et la consommation d'énergie ou pour maximiser les profits, la production, la performance et l'efficacité. En réalité, les ressources, le temps et l'argent sont toujours limités ; par conséquent, l'optimisation est beaucoup plus importante dans la pratique (Yang 2010, Yang et al 2011).

Pour tout problème d'optimisation en géotechnique, les composants intégrés du processus de géotechnique sont très diversifiés et complémentaires. Ce processus prend souvent beaucoup de temps et dans de nombreux cas, les coûts de calcul sont généralement très élevés. En outre, la modélisation constitutive classique basée sur les théories d'élasticité et de plasticité n'a qu'une capacité limitée à simuler correctement le comportement réel des géomatériaux. Ceci est attribué à des raisons associées à la complexité de la formulation et de l'hétérogénéité de sol, à l'idéalisation du comportement du matériau et à des paramètres empiriques excessifs (Sahin 2013). Pour ces raisons, les géotechniciens sont obligés de développer des conceptions sûres et économiques pour des systèmes caractérisés par de nombreux facteurs d'influence (paramètres techniques, paramètres économiques, paramètres environnementaux, paramètres géométriques, etc). Dans de tels systèmes, il devient de plus en plus difficile de trouver des solutions optimales et d'identifier ces paramètres, qui sont vraiment décisifs. Par conséquent, les procédures classiques comme les études de paramètres, les procédures « d'essai et d'erreur » et l'ajustement simple des paramètres sont de plus en plus remplacées par des techniques dites « Méthodes d'optimisation » (Konietzky et Razavi 2013), (Benbouras 2018).

L'optimisation est au cœur de tout problème lié à la prise de décision, que ce soit en ingénierie ou en économie. Le but ultime de toutes ces décisions est soit de minimiser

l'effort requis et/ou maximiser le bénéfice désiré. La résolution d'un problème d'optimisation est un problème complexe, car de nombreux facteurs interviennent et interagissent entre eux. Les problèmes d'optimisation rencontrés en pratiques ont rarement mono-objectif ; plusieurs paramètres contradictoires à satisfaire sont présents (Zidani 2013). Classiquement, un problème est dit bien posé si les sollicitations, les conditions aux limites et les paramètres du modèle sont connus. Si le système est stable, alors la réponse du modèle est unique.

L'optimisation multi objective est disponible depuis environ trois décennies, et son application dans les problèmes du monde réel ne cesse d'augmenter.

II. 2 Méthodes d'optimisation utilisées en géotechnique

Les approches utilisées dans la littérature pour résoudre des problèmes d'optimisation en géotechnique sont nombreuses. Nous énumérons quelques-unes citées, et comprenant les applications principales des méthodes d'optimisation en géotechnique :

- Les algorithmes évolutionnaires
- Optimisation par essaim de particules (PSO)
- Optimisation par Colonie d'abeilles
- Les Réseaux de Neurones Artificiels
- Les algorithmes de voisinage
- Monte Carlo
- Recherche taboue
- Le recuit simulé
- Les plans d'expériences (DOE)

Pour le choix de bonnes méthodes d'optimisations pour les bons problèmes, il existe de nombreuses observations empiriques, mais pas de lignes directrices convenues ; en fait, il n'y a pas de méthode universellement efficace pour tous les types de problèmes. Par

conséquent, le choix dépend de nombreux facteurs et est parfois soumis aux préférences personnelles des chercheurs et l'expérience des décideurs (Yang 2013).

II. 3 La méthode des plans d'expériences (DOE)

II. 3. 1 Contexte et méthodologie des plans d'expériences

L'observation et l'expérimentation ont fait partie intégrante et importante du métier des Ingénieurs et les techniciens d'études et de fabrication. En outre, les processus deviennent extrêmement compliqués avec les progrès des sciences technologiques modernes, ce qui a induit à un accroissement rapide des coûts d'expérimentation. D'autre part, l'utilisation de la méthode traditionnelle d'optimisation pour l'étude expérimentale nécessite un certain nombre de combinaisons d'expériences qui demandent beaucoup de temps, de coûts et de main-d'œuvre (Rao et al 2008) . Pour cela, plusieurs chercheurs ont développé la méthode des plans d'expérience (Dounane 2021). Les plans d'expériences (DOE) regroupe un ensemble de techniques statistiques destinées à analyser le comportement d'un système expérimental dans le but de comprendre et d'améliorer son fonctionnement.

La méthode des plans d'expérience détermine la relation entre les causes affectant un processus et les résultats du processus en établissant une relation de cause à effet entre plusieurs variables indépendantes (les facteurs) et une variable dépendante d'intérêt (la réponse), donc ils peuvent aussi identifier les interactions importantes qui peuvent être manquées lors de l'expérimentation avec un facteur à la fois (Alexis 1995, Shiri et al 2016).

De sorte que le résultat d'un processus puisse être prédit dans des conditions préalables données, il est décrit comme un modèle empirique purement descriptif basé sur les variables expérimentales dans un domaine expérimental limité (Eq II.1). Ce modèle décrira les résultats d'un processus (la réponse y) en fonction des facteurs (x_i) qui

comporte : des termes linéaires ; des termes d'interactions faisant intervenir deux variables ou plus et des termes quadratiques ou cubiques (Baillet 2017, Zhang et al 2015) : (Dounane 2021)

$$y = a_0 \sum_1^i a_i x_i + \sum_1^i a_{ij} x_i x_j + \sum_1^i a_{ij} x_i x_j x_k \dots + \sum_1^i a_{ii} x_i^2 + \sum_1^i a_{ii} x_i^3 \quad (\text{II. 1})$$

Avec y ; représente la réponse et x_i ; représente les facteurs (voir figure II.1)

a. Facteurs

Les facteurs caractérisant les conditions expérimentales peuvent être très variés, il existe : Des facteurs quantitatifs continus et discontinus, des facteurs qualitatifs, des facteurs contrôlés, des facteurs mesurables, des facteurs constants et des facteurs bruits.

b. Les réponses

Les réponses caractérisent ce que l'expérimentateur considère comme conséquence du phénomène et constituent des objectifs à optimiser. Elles peuvent, comme les facteurs, être de natures très variées comme :

Des réponses quantitatives continus et discontinus, des réponses qualitatives quantifiables, des réponses qualitatives quantifiables, des réponses binaires et des réponses sous forme de courbe (Abderrahim et Hachemi 2019).

Le processus expérimental est résumé dans la figure II.1 suivante :




FIG II.1 SCHÉMA PLAN EXPERIENCE

La méthodologie expérimentale doit être conçue comme un processus itératif entre le modèle et le plan expérimental. Elle permet de planifier les expériences pertinentes pour ajuster un modèle aux données et le valider.

II. 3. 2 La conception d'un plan d'expérience

La détermination et la compréhension des effets de différentes variables sur une autre variable en utilisation du minimum des tests et la détermination des résultats avec une bonne précision. Il nécessite de réaliser une bonne conception d'un plan d'expérience en respectant les étapes suivantes (Baillet 2017, Zhang et al 2015) : (Dounane 2021).

- Définir le problème et identifier l'objectif à atteindre en recueillir un maximum d'informations sur le phénomène étudié
- L'identification des facteurs indépendants ou influents à étudier
- L'identification des différents niveaux des facteurs et la prise en compte les facteurs de bruit observables qui peuvent influencer les expériences en tant que source d'erreur de variation.
- La sélection des réponses qui seront observées
- Réaliser des expériences et collecter des données
- Analyser les données
- Interpréter les résultats
- Vérifier les résultats prévus

II. 3. 3 Avantages des plans d'expérience

Les plans d'expérience sont une méthodologie qui caractérise par nombreux avantages, notamment : (Dounane 2021).

- Limitations du nombre d'expériences à effectuer aussi que la maîtrise de certaines propriétés statistiques aux modèles établis lors de répondre à une demande précise, donc un moindre coût économique (Baillet 2017)

- La possibilité d'étudier un grand nombre de facteurs à la fois de manière programmée et raisonnée avec la détection des interactions entre eux
- La détermination des optimaux
- L'optimisation et la modélisation des résultats
- Une précision optimum des résultats

II. 4 La méthodologie des surfaces de réponse (RSM)

II. 4. 1 Les principes généraux

Parmi les techniques multivariées les plus pertinentes utilisées dans l'optimisation analytique se trouve la méthodologie de surface de réponse (RSM) (Bezerra et al 2008). La méthodologie de surface de réponse est un outil efficace pour optimiser le processus, qui a été initialement décrite par Box et Wilson (1951) (Sun et al 2010). Elle fournit des procédures mathématiques et statistiques pour étudier les relations entre une ou plusieurs réponses (variables dépendantes) et un certain nombre de facteurs (variables indépendantes). Ce qui lui permet d'obtenir des informations à moindre coût et dans des délais plus (Karazhiyan et al 2011).

L'objectif de cette méthode est, plus que de hiérarchiser les effets des différents facteurs, de décrire le plus précisément possible le comportement de la réponse en fonction des variations des facteurs (Myers et Montgomery 2002).

Diverses méthodes de surface de réponse sont disponibles parmi eux la conception Box-Behnken (BBD) et la conception composite centrale.

La conception Box-Behnken (BBD) prend les points médians des bords de l'espace de processus et le point central en considération lors de la construction de la conception (Figure II.2), chaque variable a été codée aux niveaux, -1 , 0 et 1 (Ranade et Thiagarajan 2017), et il est composé de deux parties : le point central et les points médians des bords. Ceci est classé parmi les points de conception appelés type d'espace. Par conséquent, la

valeur haute de la variable d'origine est représentée par (+ 1) et la valeur basse est représentée par (- 1). La valeur (0) représente la moyenne de ces deux valeurs (Bagaber et Yusoff 2018). BBD est reconnu comme l'une des conceptions les plus courantes et les plus efficaces utilisées dans le RSM. L'utilisation de BBD facilite l'optimisation des paramètres effectifs avec un nombre minimum d'expériences, ainsi que l'analyse de l'interaction entre les paramètres (Polat et Sayan 2019), (Benayoun 2021).




FIG II. 2 CONCEPTION BOX-BEHNKEN A TROIS FACTEURS

0

II. 4. 2 Étapes de la méthodologie de surface de réponse

Les phases de construction du plan et de modélisation sont étroitement liées et peuvent être menées de manière itérative. Dans une première étape, on construit un plan d'expérience optimal pour le modèle le plus simple possible. Ensuite, ce plan pourrait éventuellement être complété si les phases de modélisation et de validation montrent que le modèle présupposé s'avère inadéquat. Les étapes de la RSM sont les suivantes :

Les différentes étapes à suivre pour mener à bien une expérimentation sont :

- Définir le problème, processus -objectif.
- Choisir les variables facteurs et l'espace de variation.
- Définir et comparer les designs expérimentaux.
- Exécution des expériences.

- Analyse statistique des résultats

Les différentes étapes à suivre pour mener à bien une expérimentation sont :

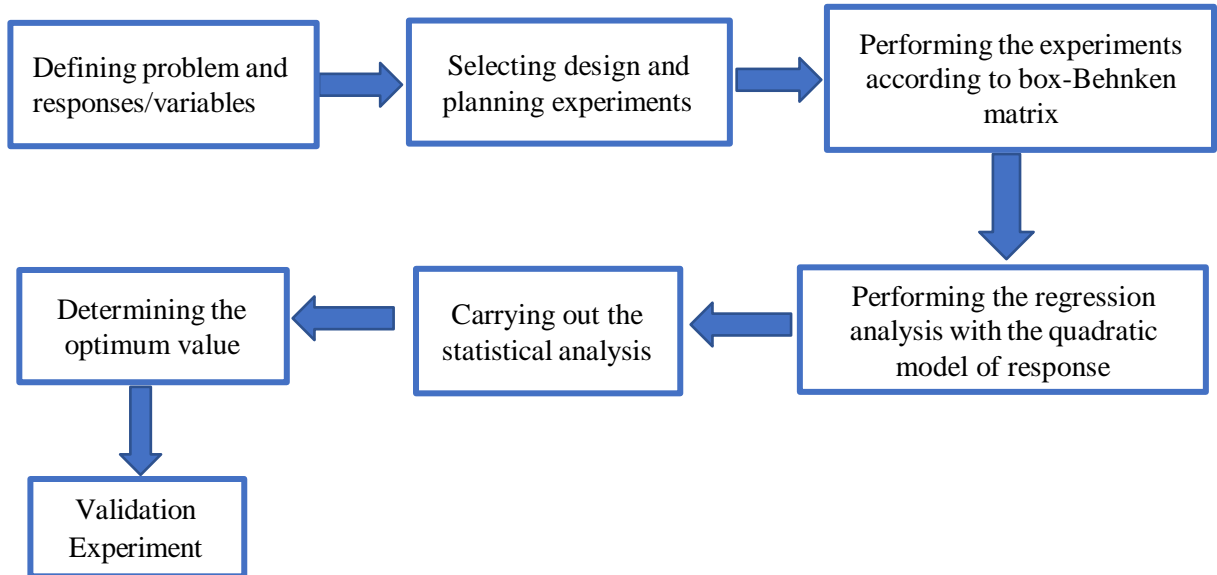


FIG II. 3 ÉTAPES IMPLIQUÉES DANS LA CONCEPTION DE BOX-BEHNKEN

II. 4. 2. 1 Planification expérimentale

Pour une bonne planification expérimentale, il est souhaitable que le nombre d'expériences effectuées, soit le plus faible possible afin de réduire les besoins informatiques, le délai et les coûts d'expérimentation. Une bonne sélection des points pour l'expérimentation permettra de réduire la variance des coefficients de notre modèle mathématique, ce qui rendra les surfaces de réponses obtenues plus fiables. Pour ce faire, il faut déterminer le plan d'expérience le plus approprié afin d'obtenir les expériences les plus intéressantes pour notre type de problème. Les plans utilisés dans le cadre d'une étude de RSM sont des plans quadratiques tels que les plans centraux composites (Box-Wilson) ou les plans de Box-Behnken (Abderrahim et al 2019).

II. 4. 2. 2 Modélisation

La modélisation empirique permettant de développer une relation d'approximation appropriée entre le rendement et les variables du processus, ainsi que des méthodes d'optimisation permettant de rechercher les variables du processus, qui produisent des valeurs souhaitables de la réponse.

Le modèle polynomial du second ordre peut s'écrire par l'équation (II.2)

$$y = \beta_0 + \sum_{i=1}^d \beta_i x_i + \sum_{i=1}^d \beta_{ii} x_i^2 + \sum_{j=2}^d \sum_{i=1}^{j-1} \beta_{ij} x_i x_j + \varepsilon \quad (\text{II. 2})$$

Où y est la réponse prévue, β_0 est le coefficient constant de modèle, β_i est le $i^{\text{ème}}$ coefficient linéaire du paramètre d'entrée x_i , β_{ii} est le $i^{\text{ème}}$ coefficient quadratique du paramètre d'entrée x_i , β_{ij} coefficient d'interaction entre les paramètres d'entrée x_i et x_j et ε est l'erreur du modèle.

L'examen d'un modèle tel que (II.2) a trois objectifs :

- **Premièrement** : établir une relation, même approximative, entre y et x_1, x_2, \dots, x_k qui peut être utilisée pour prédire les valeurs de réponse pour des valeurs données des variables.
- **Deuxièmement** : déterminer à l'aide des tests d'hypothèses la signification des facteurs.
- **Troisièmement** : déterminer les paramètres optimaux de x_1, x_2, \dots, x_k entraînant la réponse maximale (ou minimale) sur une certaine région d'intérêt. Une fois les modèles mathématiques obtenus, il est nécessaire de vérifier que ces modèles donnent une approximation adéquate du système réel à l'étude.

II. 4. 2. 3 Validation des modèles

Une fois la modélisation effectuée, il faut valider les modèles obtenus. Pour cela, des mesures statistiques importantes sont à considérer (Abderrahim et al 2019).

- le coefficient de détermination statistique : R^2
- le coefficient de détermination ajusté : R^2_{adj}
- l'erreur $RMSE$

Leurs définitions impliquent la partition de l'erreur totale :

$$SS_T = \sum_{i=1}^n (y - \hat{y})^2 \quad (\text{II. 3})$$

En une somme de l'erreur accidentelle et de l'erreur systématique.

$$SS_T = SS_R + SS_E \quad (\text{II. 4})$$

Où :

$\hat{y} = \sum_{i=1}^n \frac{y_i}{n}$ Est la moyenne de réponses.

Quant au coefficient de détermination R^2 il permet d'estimer la variation de la réponse autour de la moyenne qui peut être représentée par le modèle. Il est compris entre 0 et 1 et un R^2 de 1 exprime une correspondance parfaite entre l'évaluation et la valeur réelle $\hat{y}_i = y_j$. Par contre, un R de 0 signifie que l'évaluation est incapable de prédire la valeur réelle.

$$R^2 = 1 - \frac{SS_E}{SS_T} \quad (\text{II. 5})$$

Le coefficient de détermination ajusté R^2_{adj} est une mesure améliorée de R^2 .

Contrairement à R^2 , R^2_{adj} n'augmente pas lorsque des paramètres redondants sont ajoutés à l'approximation de surface de réponse.

$$R^2_{adj} = 1 - \left[\frac{n-1}{n-p} \right] (1 - R^2) \quad (\text{II. 6})$$

Quant à la $RMSE$, il s'agit d'une estimation de la déviation standard de l'erreur aléatoire et peut s'écrire :

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y - \hat{y})^2} \quad (\text{II. 7})$$

II. 4. 3 La RSM pour l'optimisation en ingénierie

Une fois la modélisation terminée, le problème à l'étude doit être optimisé. Plusieurs méthodes d'optimisation peuvent permettre d'optimiser simultanément les différentes réponses découlant de l'emploi de la méthode des surfaces de réponses.

II. 4. 3. 1 Méthode graphique

La première méthode de résolution est l'approche graphique. Pour cela, il suffit de tracer des courbes d'iso réponses pour chaque critère en fonction des variables, puis d'hachurer les zones intéressantes suivant les objectifs retenus. Enfin, par superposition des graphes, on fait apparaître les zones de compromis. Malheureusement, si cette méthode semble très attractive pour des cas simples avec 2 ou 3 variables, elle devient très lourde pour des problèmes plus complexes. Parce que, l'utilisateur doit jongler avec un grand nombre de graphiques pour découvrir le meilleur compromis.

II. 4. 3. 2 Méthodes numériques

- **Le quadrillage**

Cette méthode numérique présente le double avantage d'une conception simple et d'une recherche systématique. Pour réaliser cette recherche, il suffit de quadriller la zone expérimentale, et de calculer en chacun des nœuds les valeurs obtenues pour les différentes réponses. On obtient ainsi les différents points présentant des valeurs obtenues pour tous les critères. L'inconvénient majeur vient essentiellement de la difficulté d'obtenir à la fois une grande précision et un temps de calcul raisonnable :

- Un maillage trop fin augmente le temps calcul.
- Un maillage trop large risque de ne pas signaler des zones solutions qui seraient intéressantes (Abderrahim et al 2019).

II. 5 La méthode de Taguchi

Il existe de nombreux types de plans d'expériences qui diffèrent par la façon de traiter les facteurs étudiés, les niveaux associés à ces facteurs et les interactions qui peuvent exister (Alexis 1995). La méthode de Taguchi mise en œuvre des plans d'expériences, développée par Genichi Taguchi au Japon dans les années 1960, utilise les plans d'expériences fractionnaires (Anderson et Braak 2003). Ce sont des plans optimaux qui tiennent compte des effets des facteurs et de leurs interactions tout en réduisant considérablement le nombre d'essais à réaliser. La méthode d'expérimentation de Taguchi utilise un ensemble de notions dont la table orthogonale, le facteur contrôlé, le facteur bruit, le ratio signal-bruit, etc. De nos jours, cette méthode est largement utilisée dans le domaine industriel (Venkateswarlu et al 2010, Yang 2013), on s'intéresse dans ce travail à l'appliquer.

II. 5. 1 Méthodologie de la méthode Taguchi

La méthodologie de Taguchi est une approche factorielle fractionnaire qui fusionne des techniques statistiques et d'ingénierie (Mohan et al 2007). L'optimisation de la méthodologie de Taguchi consiste principalement en quatre étapes, adoptée et illustrée dans un organigramme à la Figure II.4. Pour chaque étape a un objectif distinct, reliés en effet pour effectuer le processus d'optimisation global (Rao et al 2008, Venkata et al 2005).

II. 5. 1. 1 Planification

Cette phase consiste principalement à déterminer les divers facteurs à optimiser le processus avec l'identification des conditions d'essais (déterminer le nombre d'essais à effectuer et de la manière dont elles devraient être effectuées). Ainsi qu'étudier l'effet des facteurs de processus sur la caractéristique de performance de sortie d'un produit ou procédé ou pour optimiser le processus, il faut avoir une compréhension générale du

processus global à étudier, et sélectionner les facteurs a priori le plus influent pour l'étude (identification des facteurs de contrôle et de bruit).

II. 5. 1. 2 Réalisation

Dans cette phase, des expériences conçues à l'aide des tableaux orthogonaux spéciaux sont réalisées. Les tableaux sont utilisés pour la conception de paramètres robustes, dans lesquelles un tableau orthogonal (OA) impliquant des variables de contrôle a été croisé avec un (OA) pour les variables incontrôlables/de bruit. Dans la méthodologie Taguchi, il a établi des tableaux orthogonaux (OA) pour décrire un grand nombre de situations expérimentales principalement pour réduire les erreurs expérimentales et pour améliorer l'efficacité et la reproductibilité des expériences. Donc, effectuez les expériences en fonction de l'ordre du tableau orthogonal et Calculez le rapport S/N.

II. 5. 1. 3 Analyse

Cette phase consiste l'analyse des données des expériences avec des logiciels spéciaux (comme Minitab, Excel. . .), et la prédiction des conditions optimales aussi que l'interaction de facteur

Vérifiez les paramètres de processus optimaux grâce à l'expérience de confirmation.

II. 5. 1. 4 Validation

Dans cette phase, les résultats obtenus et la mise en œuvre des solutions sont vérifiés par des expériences de suivi (Dounane 2021).

L'application efficace des méthodes Taguchi dans la conception expérimentale nécessite, une planification, une connaissance des processus, une communication, les compétences statistiques et le travail d'équipe sont nécessaires. De plus, fournir le bon environnement et bonnes personnes (Rao et al 2008).

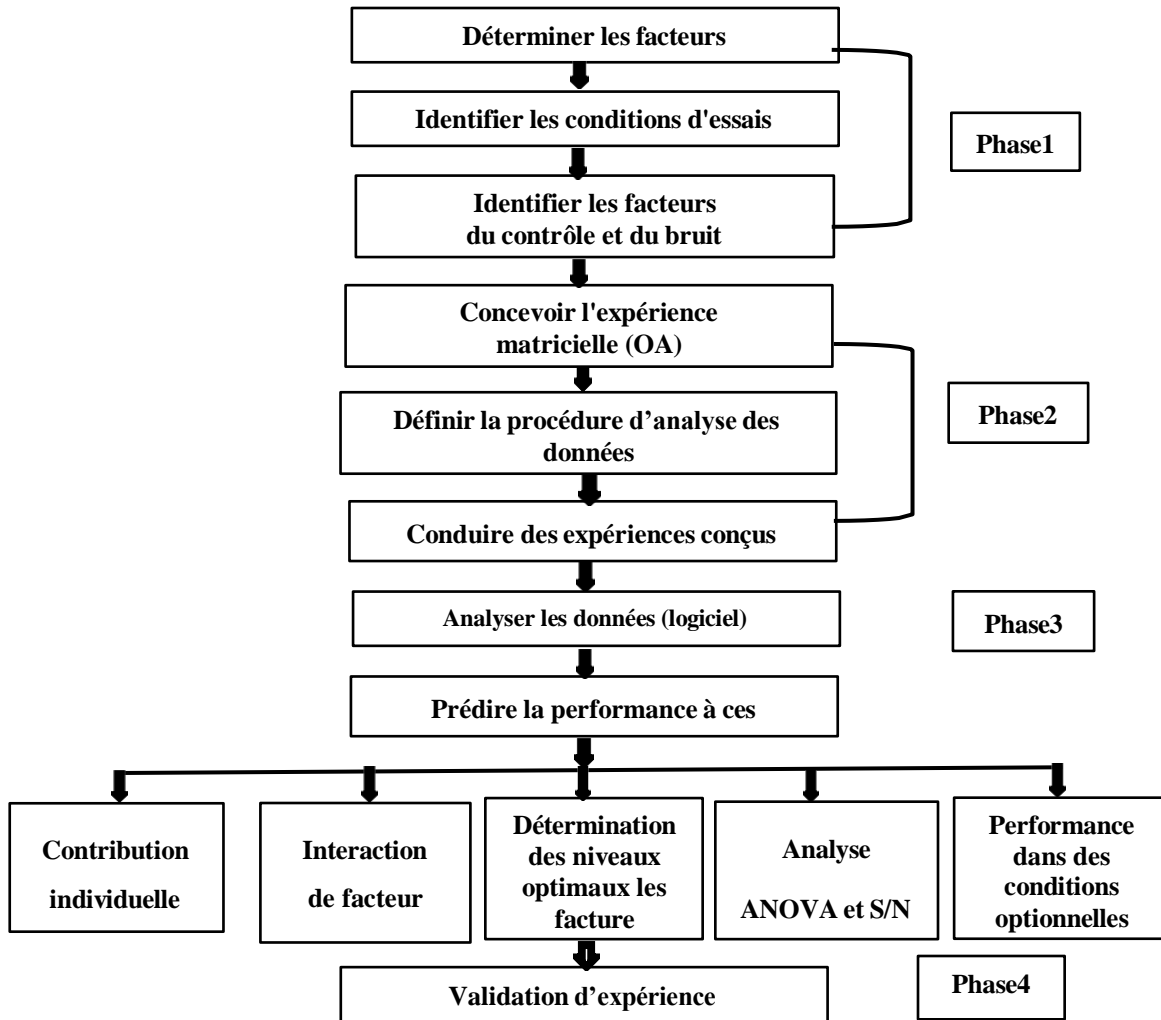


FIG II.4 REPRESENTATION SCHEMATIQUE DE LA METHODOLOGIE TAGUCHI

II. 5. 2 La notion d'orthogonalité

La méthode Taguchi utilise des matrices spéciales "appelées tableaux orthogonaux (OA)" pour étudier un grand nombre de variables avec le minimum d'expériences, ce qui réduit considérablement le nombre de configurations expérimentales à étudier (Mohan et al 2007). (Madic et al 2011, Olabi et al 2006). Un tableau orthogonal est une petite fraction du plan factoriel complet, il est appelé orthogonal, car pour chaque paire de paramètres, toutes les combinaisons de niveaux de paramètres se produisent un nombre égal de fois (Madic et al 2011, Rao et al 2008). Cette approche utilise des graphiques linéaires, une technique simple permettant de déterminer la relation entre les

variables en se concentrant sur les interactions supposées affecter les caractéristiques fonctionnelles étudiées. Autres propriétés de tableau orthogonal, où il facilite l'identification de l'influence des facteurs individuels grâce à sa conception équilibrée, en établissant la relation entre les facteurs et les conditions opérationnelles et la performance aux niveaux optimaux obtenus (Mohan et al 2007).

Enfin, un tableau orthogonal est sélectionné par l'utilisateur en fonction du nombre de facteurs, des interactions et de leur niveau ; les conclusions tirées par l'expérience à petite échelle sont valables pour l'ensemble de l'espace expérimental couvert par les facteurs de contrôle et leurs niveaux d'ajustement (Mohan et al 2007, Phadke 1995, Shetty et al 2009). L'idée principale est de se concentrer uniquement sur certaines expériences essentielles à l'analyse.

La méthodologie Taguchi utilise plusieurs types des tableaux orthogonaux qui se concentrent sur les effets principaux et augmente l'efficacité et la reproductibilité des expériences à petite échelle (Baillet 2017, Rao et al 2008, Taguchi et al 2005). Dans notre travail nous utilisons, Tableaux orthogonaux avec des séries à trois niveaux L27 (Dounane, N. 2021).

II. 5. 3 Le rapport Signal/Bruit

Taguchi partent du principe que les facteurs à l'origine de la variabilité ne peuvent pas tous être contrôlés. Ces facteurs incontrôlables sont appelés facteurs de bruit. Les plans de Taguchi essaient d'identifier les facteurs contrôlables (facteurs de contrôle) qui minimisent l'effet des facteurs de bruit. Pendant l'expérimentation, on manipule les facteurs de bruit de manière à imposer une variabilité, puis on détermine les paramètres de facteurs de contrôle optimaux qui rendent le procédé ou le produit plus robuste ou plus résistant face à la variation provoquée par les facteurs de bruit.

Le rapport (S/N) est défini comme le signal désiré par rapport à la valeur de bruit aléatoire indésirable aux caractéristiques de la qualité des données expérimentales

(Shetty et al 2009) (Shiri et al 2016), ce qui explique la sensibilité de la sortie de l'expérience aux facteurs de bruit (Olabi et al 2006). L'amélioration de la qualité par la réduction de la variabilité et l'amélioration de la mesure sont les avantages principaux des applications dans lesquels le concept de rapport S/N est utile (Shetty et al 2009). En outre, L'indice de robustesse de la qualité, le rapport S/N, montre l'ampleur de l'interaction entre les facteurs de contrôle et les facteurs de bruit (Dounane 2021).

Taguchi classe les problèmes de conception de paramètres robustes en trois catégories en fonction de l'objectif du problème, y compris le plus grand est le meilleur, le nominal est le meilleur et le plus petit est le meilleur. Ces caractéristiques de performance sont évaluées à l'aide des équations suivantes (Tan et al 2005, Yildiz et al 2007, Zhang et al 2015) :

- Plus grand est le mieux : Dans cette situation, la valeur cible de y, c'est-à-dire la variable de qualité, est infinie et le rapport S/N est défini comme suit :

$$\frac{S}{N} = -10 \log_{10} \left(\frac{1}{n} \sum_{i=1}^n \frac{1}{y_i^2} \right) \quad (\text{II. 8})$$

- Plus petit est le mieux : Pour ce type de problèmes, la valeur cible de y, c'est-à-dire la variable de qualité, est Zéro. Dans cette situation ; le rapport signal sur bruit est défini comme suit ;

$$\frac{S}{N} = -10 \log_{10} \left(\frac{1}{n} \sum_{i=1}^n y_i^2 \right) \quad (\text{II. 9})$$

- Nominal le meilleur : Pour ce type de problème, la valeur de cible donnée est donnée pour la valeur y. Dans cette situation, le rapport S/N est défini comme suit :

$$\frac{S}{N} = -10 \log_{10} \left(\frac{1}{n} \sum_{i=1}^n (y_i - y_0)^2 \right) \quad (\text{II. 10})$$

Où :

S/N : sont des statistiques de performance, définies comme le rapport signal sur bruit ;

n : le nombre de répétitions pour une combinaison expérimentale ;

y_i : une valeur de performance de la $i^{\text{ème}}$ expérience et la valeur nominale y_0 souhaitées.

II. 5. 4 Avantages et limites des plans d'expériences de Taguchi

La méthode de Taguchi est très pratique pour les chercheurs ayant un grand nombre d'expériences, du fait qu'ils peuvent acquérir rapidement et avec précision des informations techniques pour concevoir et produire des produits et des processus extrêmement fiables, et peut également être utilisée comme alternative au plan expérimental factoriel complet. L'un des avantages de la méthode de Taguchi par rapport aux méthodes de conception expérimentale classiques, outre le fait de maintenir significative du temps et des coûts nécessaires pour les investigations expérimentales, est de minimiser la variabilité autour de la cible lorsque la valeur de performance est atteinte.

D'autres avantages d'application cette méthode comprends l'optimisation des paramètres de conception, l'évaluation de la contribution significative de chacun des facteurs de conception, la prédiction des valeurs variables dans des conditions qui n'ont pas été utilisées dans le modèle original de Taguchi et que les conditions de travail optimales déterminées à partir des travaux de laboratoire peuvent être reproduites dans l'environnement de production réel (Mohan et al 2007, Rao et al 2008, Shiri et al 2016, Tan et al 2005, Zhang et al 2015). La Figure II.5 représente la différence entre l'approche classique des plans d'expériences et l'approche de Taguchi (Rao et al 2008) (Dounane 2021).

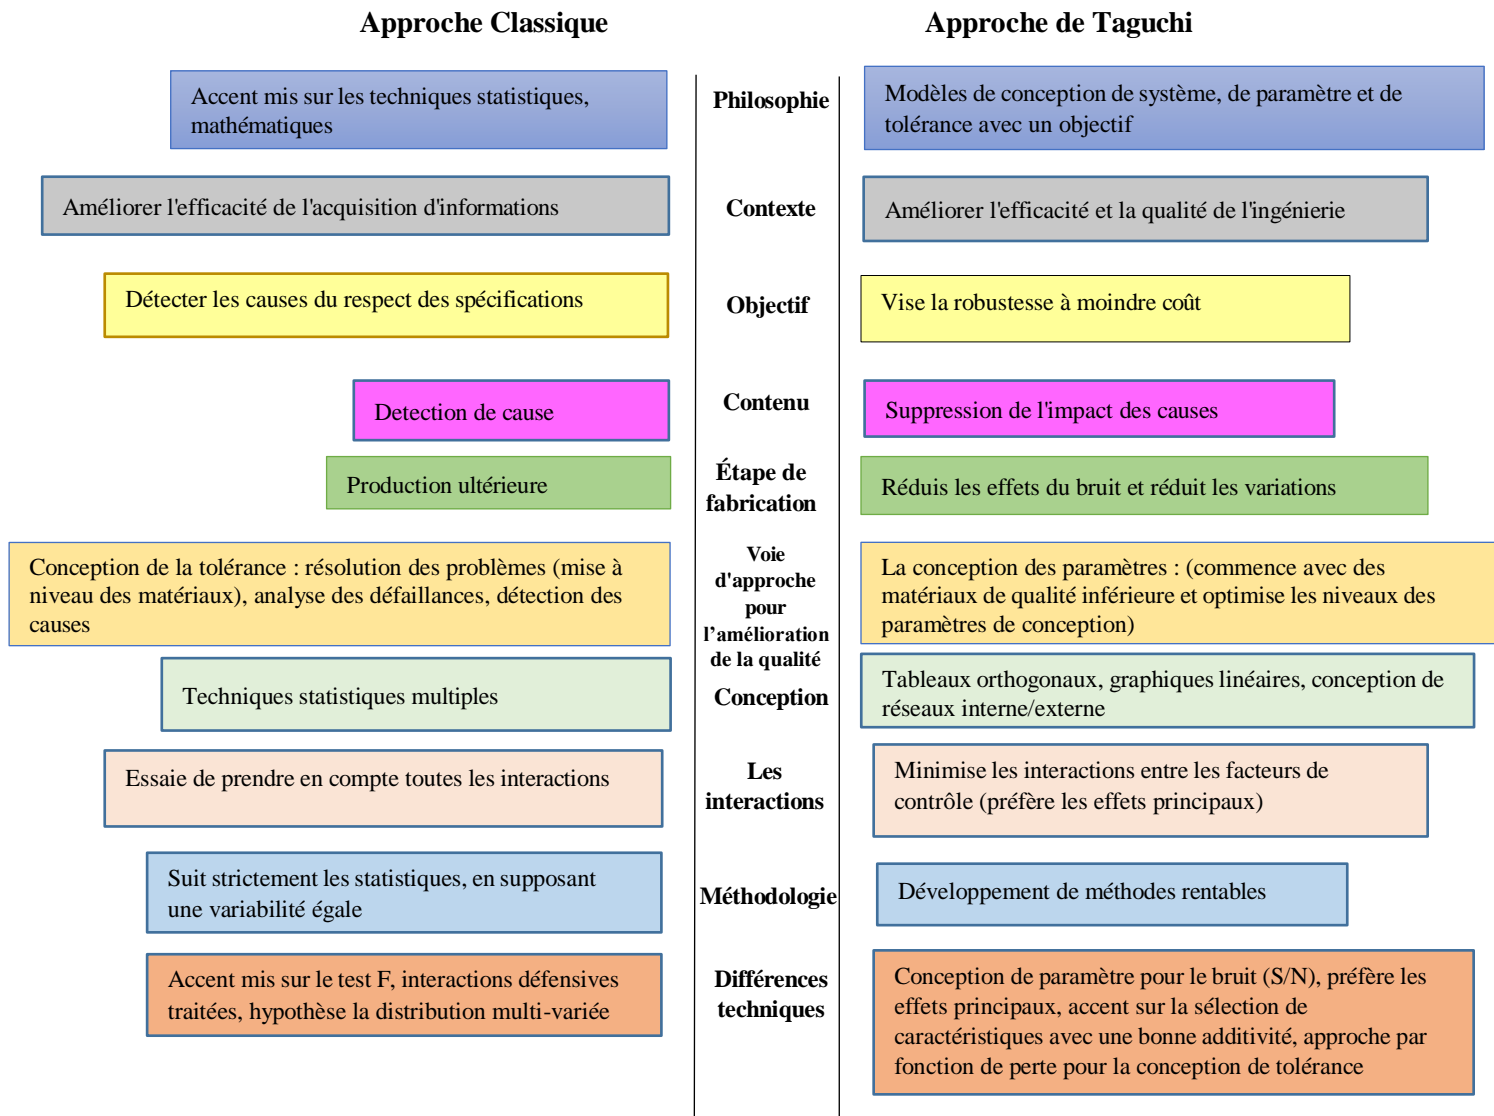


FIG II.5 ILLUSTRATION DE COMPARAISON DE L'APPROCHE DE TAGUCHI ET L'APPROCHE CLASSIQUE

II. 5. 5 Application de la méthode Taguchi

La méthode de Taguchi a été utilisée avec succès, pour la détermination des paramètres de processus optimaux, dans le monde entier pour de nombreuses applications de fabrication et de recherche (Sadeghi et al 2012, Shiri et al 2016). Elle a été initialement utilisée pour améliorer la qualité des produits manufacturés, mais plus récemment, elle a été appliquée largement et avec succès à d'autres domaines tels que l'aérospatial ;

l'environnement ; l'énergie ; etc. (Taguchi 1990, Zhanget al 2015). Plus de détails sur l'application de cette technique, dans divers domaines, sont décrits par (Sadeghi et al 2012).

En outre, la méthode de Taguchi a été appliquée avec succès au domaine de génie civil tels que la construction (Polat et al 2019) ; l'étude de la stabilité de pentes (Tan 2006) ; l'érosion des sols (Sadeghi et al 2012, Zhang et al 2015) ; liquéfaction du sol (Baykasoglu et al 2009) ; les tunnels (Gong et al 2014) ; etc.

II. 5. 6 La méthode de Taguchi et l'analyse de variance (ANOVA)

Comme mentionner précédemment, la méthode Taguchi utilise le plan orthogonal et l'analyse de la moyenne pour analyser les effets de paramètres, basés sur l'analyse statistique des expériences. Cependant, il nécessite diverses analyses doivent être effectuées pour déterminer la fiabilité des résultats expérimentaux et le degré d'effet des paramètres sur le résultat. Pour cela, une technique statistique standard appelée analyse de variance (ANOVA), couramment utilisée pour fournir une mesure de la confiance (Tan 2006, Yıldız et al 2007).

L'analyse ANOVA est une méthode statistique simple, puissante et populaire consiste à vérifier les différences entre les moyennes des méthodes/groupes en examinant l'ampleur de la variation dans chacun des groupes, par rapport à l'ampleur de la variation entre les groupes/méthodes (Quinn et al 2002, Rani et al 2013).

L'analyse d'ANOVA est particulièrement adaptée aux conceptions expérimentales impliquant l'appariement ou le blocage, à des mesures répétées sur les mêmes sujets, ou pour vérifier si différents facteurs de l'expérience interagissent avec les uns aux autres. Elle a été utilisée en plusieurs domaines, notamment, dans les sciences biologiques, la psychologiques, le médicales, l'écologiques et environnementales (Anderson, et al 2003) ; aussi au domaine de la géotechnique (Rani et al 2013).

II. 6 Conclusion

Dans le large panorama des méthodes d'optimisation discrètes adaptées aux problèmes d'optimisation géotechniques nous avons le choix d'utiliser la technique la plus adaptée à notre problème et la disponibilité des données nécessaires pour le résoudre.

Dans ce chapitre, nous avons exploré la méthode des plans d'expériences, dont son objectif est plus que de hiérarchiser les effets des différents facteurs, elle cherche à décrire le plus précisément possible le comportement de la réponse en fonction des variations des facteurs.

Cette méthode est efficace pour une meilleure organisation de la démarche expérimentale et résoudre les problèmes d'optimisation lors d'une étude. En outre, parmi ces méthodes Taguchi et la surface de réponse (RSM) sont des techniques réussies pour améliorer la technologie, et le succès de son application nécessite le respect toutes les étapes de la méthodologie de conception mentionnée ci-dessus. Dans ce contexte, la méthode de Taguchi et la surface de réponse (RSM) ont été utilisées pour la présente étude.

Chapitre III

Généralités sur l'Apprentissage Automatique

III.1 Introduction

La sélection de l'algorithme d'apprentissage est un élément clé dans la conception d'un système automatique. De nombreuses approches mathématiques permettent de représenter et d'entraîner ces systèmes. Lorsque nous cherchons à mettre en place un apprentissage automatique deux facteurs décisifs doivent être pris en compte : les données et le choix de l'algorithme.

L'apprentissage automatique est un sous-domaine de l'intelligence artificielle qui vise à développer des algorithmes capables d'apprendre à partir de données. Ces données, qui peuvent être naturelles, synthétiques ou générées par d'autres algorithmes, servent d'exemples pour entraîner ces modèles.

Dans ce chapitre tout d'abord, nous présentons la renaissance de l'apprentissage automatique, en donnant un bref aperçu historique allant des prémises à l'essor de ce domaine. Ensuite, nous explorerons les différentes approches de l'apprentissage automatique, en mettant l'accent sur l'apprentissage supervisé, non supervisé et par renforcement. Avant de conclure ce chapitre, nous décrivons les concepts clés, les principes de fonctionnement et la manière de tester et de valider quelque type des modèles d'apprentissage automatique tel que : Extreme Gradient Boosting (XGBoost), la forêt aléatoire (RF) et le Réseau de neurones artificiels (RNA).

III.2 Définition de l'intelligence artificielle

De nombreuses industries ont été révolutionnées par l'intelligence artificielle (IA), rendue possible par la capacité des machines à effectuer des tâches complexes. L'IA implique le traitement de grands ensembles de données sensibles, telles que l'analyse des données et la reconnaissance de formes, à l'aide des prédictions de l'IA. Cette technologie a joué un rôle essentiel dans le développement et le fonctionnement de l'industrie du génie civil, rendant de nombreux processus d'ingénierie plus précis et efficaces.

Certains domaines inclus dans le développement de l'IA sont l'apprentissage automatique et les réseaux de neurones artificiels, le traitement du langage naturel, la robotique et la vision par ordinateur. Au plus haut niveau, les systèmes d'IA utilisent des méthodes de prise de décision et d'optimisation, des formalismes de représentation des connaissances et des techniques de résolution de problèmes telles que le raisonnement logique, les méthodes de recherche et les méthodes probabilistes, entre autres. L'IA récemment a réalisé de nombreux progrès grâce à la disponibilité de grands ensembles de données, de techniques informatiques avancées et de meilleurs algorithmes et modèles pour atteindre cet objectif, ce qui conduit à des progrès remarquables dans le traitement de la parole, le traitement des images et des signaux et les systèmes autonomes.

III. 2. 1 Sous-domaines de l'intelligence artificielle

L'IA et ses progrès continus doivent beaucoup à la richesse de ces sous-domaines qui peuvent généralement être considérés comme des éléments de base dans la poursuite de la réplique de la cognition humaine (Figure III.1) :

III. 2. 1. 1 Apprentissage automatique

L'apprentissage automatique (ML) existe comme l'un des sous-domaines les plus importants dans lesquels les machines apprennent et développent la capacité d'améliorer leurs performances en interagissant avec les données pour l'accomplissement de tâches déterminées.

III. 2. 1. 2 Deep Learning

Il existe une vaste branche appelée techniques d'apprentissage profond (Deep learning techniques) qui fait partie du domaine du ML dans lequel nous utilisons des réseaux de neurones artificiels ressemblant à la structure du cerveau humain pour résoudre des problèmes complexes (Djelailia, D 2024).

Parmi ces tâches :

- a) La vision par ordinateur qui permet aux machines de percevoir et d'interpréter le monde réel à partir d'images ou de vidéos. Cette technologie est essentielle dans de nombreux domaines, tels que la conduite autonome, le diagnostic médical assisté par ordinateur et la surveillance vidéo.
- b) Le traitement du langage naturel qui vise à permettre aux machines de comprendre, d'interpréter et de générer du langage humain. Cette technologie facilite la communication entre les humains et les machines, et trouve des applications dans des domaines variés tels que l'analyse des sentiments, la traduction automatique, et la recherche d'informations.

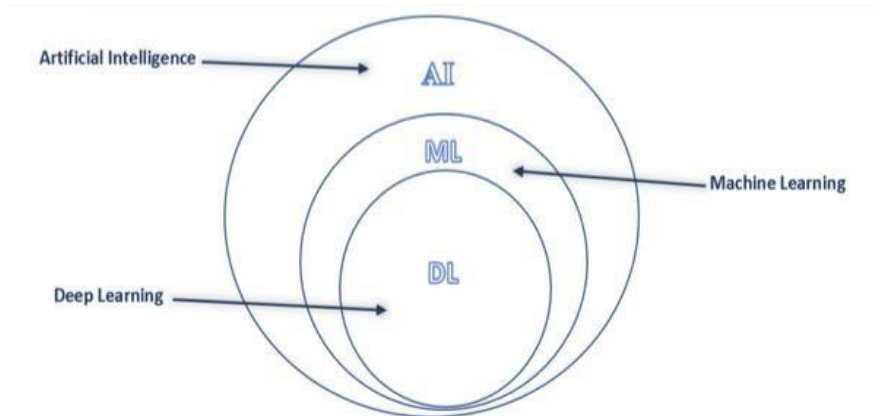


FIG III. 1 SOUS-DOMAINES DE L'INTELLIGENCE ARTIFICIELLE

Ces derniers sont parmi les sous-domaines qui représentent certains des nombreux domaines de spécialisation en plein essor au sein de l'intelligence artificielle. La robotique, la planification et l'ordonnancement ne sont que quelques-uns des domaines parmi eux. En outre, ces sous-domaines de recherche continueront sans aucun doute à se développer et à interagir davantage les uns avec les autres, donnant ainsi forme aux nouveaux paradigmes que les machines seront capables d'apprendre et d'accomplir dans le futur de l'IA (Mohri et al 2012).

III. 3 Définition de l'apprentissage automatique (ML)

L'apprentissage automatique est souvent défini comme un sous-ensemble de l'intelligence artificielle et de l'apprentissage statistique qui inclut des techniques utilisées pour créer des modèles prédictifs. Il est basé sur le concept de la capacité des systèmes à améliorer leur capacité à prendre des décisions avec peu de référence aux données, ainsi que sur la capacité générale d'un système à discerner des modèles et à prendre des décisions par lui-même.

La modélisation prédictive doit être réalisée à l'aide de l'apprentissage automatique dans lequel les algorithmes apprendront à partir d'un ensemble de données initial appelé données d'entraînement afin de pouvoir généraliser les données d'apprentissage à de nouvelles données sans avoir été programmé pour le faire (Mitchell 1997).

En apprentissage automatique, le choix du modèle, qu'il s'agisse d'un problème de classification ou de régression, est crucial pour la performance. Ce choix est conditionné par de multiples facteurs tels que la taille et la nature des données, la complexité de la tâche et les hypothèses sous-jacentes.

III. 4 La renaissance de l'apprentissage automatique

L'apprentissage automatique est une discipline jeune, à l'instar de l'informatique et de l'intelligence artificielle. Il se situe au carrefour d'autres disciplines : philosophie, psychologie, biologie, logique, mathématique (Cornuéjols et al, 2002). Les premières études remontent à des travaux de statistique dans les années 1920. C'est après la seconde guerre mondiale que les premières expériences deviennent possibles. Le terme d'apprentissage automatique (machine learning) est utilisé pour la première fois lors de la présentation de programme jouant aux dames, capable de s'améliorer au fil des parties, présenté en 1959 par Arthur Samuel, un informaticien américain.

Cette discipline a été développée ensuite dans les années 1960 les approches connexionnistes avec des perceptrons, et la reconnaissance des formes. La mise en

évidence des limites du perceptron simple arrête toutes les recherches dans ce domaine jusqu'à la renaissance dans les années 1980. Les années 1970 sont dominées par des systèmes mettant l'accent sur les connaissances, les systèmes experts, Les limites de tels systèmes se font sentir dans les années 1980, pendant lesquelles a lieu le retour du connexionnisme avec un nouvel algorithme d'apprentissage (Cornuéjolset al 2002).

Les mathématiciens commencèrent à s'éloigner du cadre cognitif de l'apprentissage pour envisager le problème sous l'angle de l'optimisation, pendant qu'apparaissaient de nouvelles méthodes comme les arbres de décision ou l'induction de programmes logiques. L'influence de la théorie statistique de l'apprentissage s'est réellement fait sentir dans les années 1990, avec l'ouvrage de Vapnik 1995. C'est également à cette époque que se développent sérieusement les premiers algorithmes d'apprentissage profond (deep learning), en particulier les réseaux de neurones artificiels. Qui se reviennent sur le devant de la scène aux années 2010, poussés par l'augmentation de la puissance de calcul et par la mise à disposition de bases de données plus importantes, favorisant l'utilisation des algorithmes d'apprentissage profond. Les techniques d'apprentissage profond imposent rapidement leur suprématie dans le domaine de la classification d'image. Basé également sur des réseaux de neurones comme modèles de prédiction.

III. 5 Catégories de l'apprentissage automatique (Machine Learning)

Il existe de nombreux types de systèmes d'apprentissage automatique (Figure III. 2). Dans ce qui suit, nous les classons selon qu'ils nécessitent ou non une supervision humaine (supervisés, non supervisés et apprentissage de renforcement).

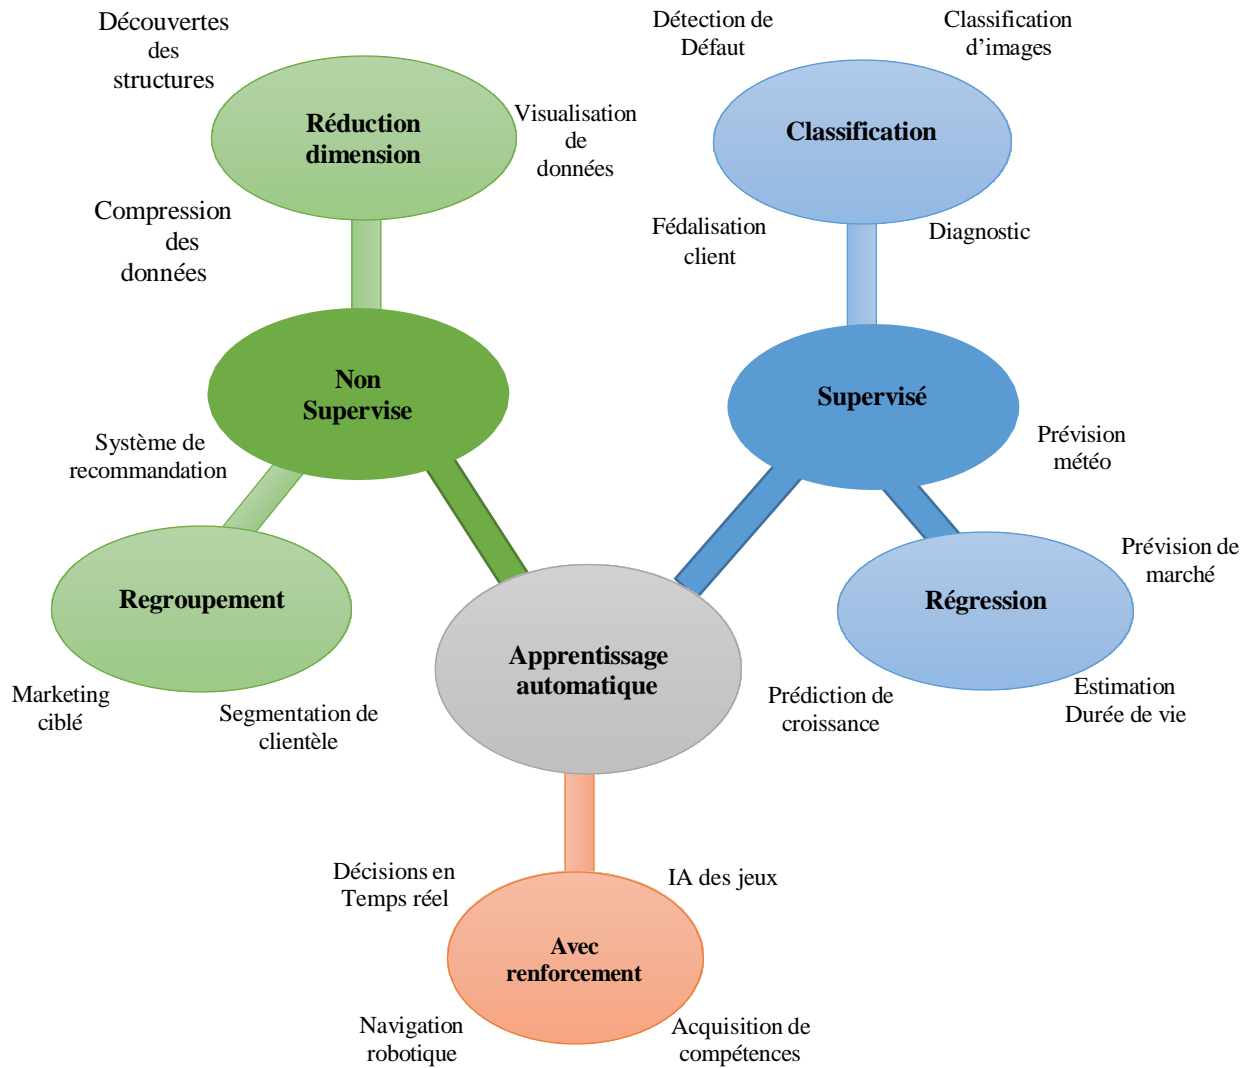


FIG III. 2 CATEGORIES D'APPRENTISSAGE AUTOMATIQUE

III.5.1 Apprentissage supervisé

On parle d'apprentissage supervisé lorsque l'on dispose de données d'entraînement étiquetées, c'est à dire dont on connaît la sortie voulue. En notant les N entrées x_i et les sorties cibles associées, on dispose de l'ensemble de données $D = \{x_i, y_i\} i \in [1, N]$.

L'objectif est d'entraîner le modèle choisi pour qu'il puisse prédire correctement la sortie pour des entrées non étiquetées, C'est-à-dire trouver une représentation générale de l'entrée à la sortie pour la cartographie qui puisse ensuite être utilisée sur d'autres points de données qui n'ont pas été vus auparavant.

La marge d'erreur se réduit avec chaque itération de l'apprentissage, pour but d'être capable de généraliser son apprentissage à de nouveaux cas. Ce type d'apprentissage ne peut donc être mis en place que lorsque nous avons des données d'entraînement qui sont annotées. Des exemples d'algorithmes d'apprentissage supervisé incluent les arbres de modèles de régression linéaire et les machines à vecteurs de support, ... etc sont décrits dans les parties qui suivent. Ces derniers peuvent résoudre des problèmes de classification et/ou de prédiction.

III. 5. 1. 1 La classification

La classification est une tâche de modélisation prédictive largement utilisée dans le domaine de l'apprentissage automatique, qui consiste à prédire une étiquette pour des données d'entrée. Elle nécessite un ensemble de données d'entraînement avec un large éventail d'instances d'entrées et de sorties à partir desquelles le modèle apprend.

L'ensemble de données d'apprentissage est utilisé pour trouver la manière minimale de faire correspondre les échantillons de données d'entrée aux étiquettes de classe spécifiées.

Enfin, l'ensemble de données d'apprentissage représente la question qui contient un grand nombre d'échantillons de sortie.

Il est utilisé pour le filtrage des spam, la recherche de documents, la reconnaissance des caractères manuscrits, la détection des fraudes, l'identification des langues et l'analyse des sentiments. Dans ce cas, le résultat est discret.

III. 5. 1. 2 La régression

Dans ce modèle, le résultat est toujours continu. L'analyse de régression est essentiellement une approche statistique qui modélise un lien entre une ou plusieurs variables indépendantes et une variable cible ou dépendante.

La régression permet de voir comment le nombre de la variable dépendante change en fonction de la variable indépendante alors que les autres variables indépendantes sont constantes.

L'analyse de régression est une méthode de "meilleure estimation" qui génère une prévision à partir d'un ensemble de données. En d'autres termes, il s'agit d'ajuster différents points de données dans un graphique afin d'obtenir la valeur la plus précise. Parmi les algorithmes d'apprentissage supervisé classiques, on peut citer l'algorithme des k plus proches voisins, la régression linéaire, la régression logistique et les modèles tels que les réseaux de neurones, les arbres de décision, les forêts aléatoires et les machines à support de vecteur.

III. 5. 2 Apprentissage non-supervisé

On parle cette fois d'apprentissage non supervisé si les données ne sont pas étiquetées. On dispose donc de données d'entrée dont on ne connaît pas la sortie associée. L'ensemble de données est donc $D = \{x_i\}_{i \in [1, N]}$ et l'objectif du système est d'identifier des caractéristiques, découvrir des groupements de données et des modèles cachés sans nécessiter d'intervention humaine, et réduire le nombre fini de caractéristiques d'un modèle à l'aide du processus de réduction de la dimensionnalité. Il s'agit de rechercher une nouvelle structure au sein des données, il ne s'agit pas de découvrir une nouvelle structure pour les données.

C'est-à-dire l'objectif du système automatique est d'inférer une caractérisation des données d'entrée : il doit capturer de lui-même les structures sous-jacentes aux données. Cet apprentissage se base principalement sur deux méthodes : la méthode par regroupement et la méthode de réduction de la dimensionnalité.

III. 5. 2. 1 Le regroupement

Les algorithmes de regroupement (clustering) cherchent à séparer les données d'entrée en un nombre donné de groupes. Chaque élément du groupe doit avoir des caractéristiques proches de celles des éléments du même groupe mais des caractéristiques relativement éloignées de celles des autres groupes. C'est-à-dire le regroupement va chercher à minimiser l'inertie intra classe (les distances entre les échantillons d'une même classe). Elle va en même temps chercher à maximiser l'inertie interclasse (les distances entre les entres de chaque classes).

Les techniques de clustering cherchent à décomposer un ensemble d'individus en plusieurs sous-ensembles les plus homogènes possible, ces algorithmes regroupent donc les entrées en familles afin de les étiqueter automatiquement.

Les algorithmes de clustering ou de regroupement les plus courants sont le clustering hiérarchique, le clustering basé sur la densité, le clustering par déplacement de la moyenne et le clustering par k-moyennes. Chaque algorithme est utilisé différemment pour trouver des grappes, mais l'objectif est le même dans tous les cas.

III. 5. 2. 2 Réduction de la dimensionnalité

Il s'agit d'une méthode de réduction des diverses variables aléatoires considérés pour obtenir un ensemble de variables principales. En d'autres termes, le processus de réduction de la dimension de l'ensemble de caractéristiques est appelé réduction de la dimensionnalité.

L'algorithme le plus répandu de ce modèle est l'analyse en composantes principales.

La malédiction de ce modèle fait référence au fait d'ajouter plus de données aux activités de modélisation prédictive, ce qui les rend encore plus difficiles à modéliser. Il est généralement utilisé pour la visualisation des données.

III. 5. 3 Apprentissage par renforcement

L'apprentissage par renforcement consiste à apprendre en interagissant avec son environnement. Un système de récompenses permet de renforcer les bons choix du modèle et pénaliser les mauvais choix. Le modèle est initialisé aléatoirement et adapte sa stratégie en fonction de son expérience durant la phase d'entraînement. Il s'agit d'un fonctionnement itératif. À chaque itération le modèle réalise une tâche et un score lui est attribué en fonction de ses performances. Les paramètres du modèle sont ensuite légèrement modifiés et la tâche est répétée. Un meilleur score oriente le choix des paramètres vers certaines valeurs, assurant que le modèle se rapproche à terme de résultats satisfaisants. Le choix des récompenses et pénalités à appliquer est donc très important car il conditionne les résultats du modèle final.

Les avantages de cette approche ont été largement et particulièrement adoptés dans des domaines tels que la robotique, les jeux et les voitures autonomes.

III. 6 Algorithmes d'apprentissage supervisé

III. 6. 1 Régression linéaire

La régression linéaire représente une approche très simple pour l'apprentissage supervisé. En particulier, la régression linéaire est un outil utile pour prédire une réponse quantitative. Bien qu'elle puisse sembler un peu ennuyeuse par rapport à certaines approches d'apprentissage statistique plus modernes, la régression linéaire reste une méthode d'apprentissage statistique utile et largement utilisée. En outre, elle constitue un bon point de départ pour de nouvelles approches qui sont considérées comme des généralisations ou des extensions de la régression linéaire (Friedman et al, 2001).

III. 6. 1. 1 Régression linéaire simple

La régression linéaire simple porte bien son nom : il s'agit d'une approche linéaire très simple, dans le cas d'une régression linéaire simple, le modèle de régression établit une

relation entre la variable d'entrée indépendante, soit la variable explicative (X), et la variable de sortie continue, soit la variable à expliquer (Y). Ainsi, le modèle doit commencer avec la fonction d'hypothèse suivante :

$$Y = B_0 + B_1X \quad (\text{III. 1})$$

Ici, β_0 correspond à l'intersection et β_1 correspond au coefficient de X, soit la pente. Dans le cas d'un apprentissage supervisé, il est prévu que les valeurs de X et Y soient données, lors de l'entraînement du modèle (Figure III.3). Lors de ce processus, le modèle détermine la meilleure ligne droite, afin de prédire la valeur de Y en fonction de la valeur de X donnée. Pour cela, le modèle doit identifier les meilleures valeurs pour B_0 et B_1 , tout en itérant à travers les données d'entraînement. Afin de déterminer les valeurs optimales pour B_0 et B_1 et évaluer la performance du modèle, nous pouvons utiliser des mesures d'évaluation. La plus répandue, pour mesurer la performance d'un modèle de régression, est la racine de l'erreur quadratique moyenne, qui correspond à la racine carrée de la moyenne des erreurs quadratiques. La formule est la suivante :

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y})^2} \quad (\text{III. 2})$$

Dans cette formule :

n :est le nombre total de point de données

y_i :est la valeur de sortie réelle

\hat{y} :est la valeur de sortie prédite

Une fois les valeurs optimales identifiées, le modèle devrait pouvoir établir une relation linéaire avec l'erreur minimale.

D'autres mesures d'évaluation, comme l'erreur quadratique moyenne (RMSE), l'erreur moyenne en pourcentage absolu (MAPE), le coefficient de variation (COV) ou encore le coefficient de détermination (R^2) peuvent être utilisées.

Cependant, il existe certains cas pour lesquels la variable à expliquer ne dépend pas que d'un seul facteur. Ainsi, nous aurons besoin d'un modèle pour évaluer des situations un peu plus complexes : nous utiliserons la régression linéaire multiple.

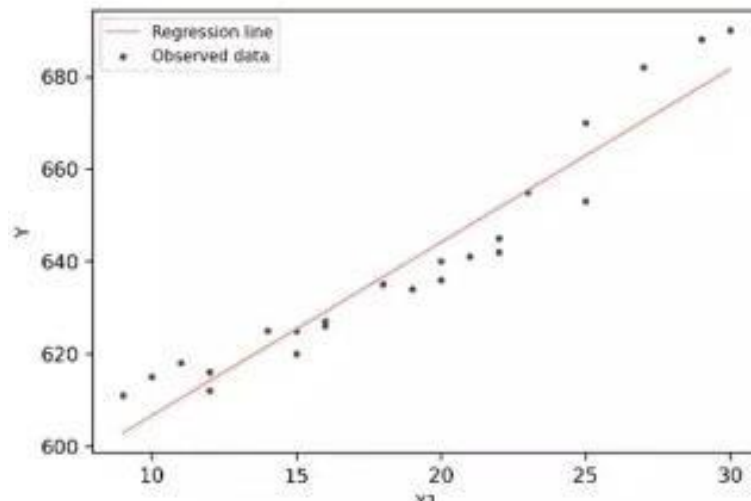


FIG III. 3 RÉGRESSION LINÉAIRE

III. 6. 1. 2 Régression linéaire multiple

Dans certains cas, la variable de sortie (y), que nous essayons de prédire, dépend de plus d'une variable. Ainsi, un modèle plus élaboré, qui prend en compte cette dimension supérieure, est nécessaire. C'est ce qu'on appelle la régression linéaire multiple (Figure III.4). L'utilisation d'un plus grand nombre de variables indépendantes peut permettre d'améliorer la précision du modèle, tant que les variables ajoutées sont pertinentes à

celui-ci. Par exemple, un modèle de régression linéaire multiple basé sur trois variables indépendantes suivrait le format suivant :

$$y = \theta_0 + \theta_1x_1 + \theta_2x_2 + \theta_3x_3 \quad (\text{III. 3})$$

De la même manière que pour la régression linéaire simple, des mesures d'évaluation peuvent être utilisées pour déterminer la performance optimale.




FIG III.4 REGRESSION LINEAIRE MULTIPLE

III. 7 Flux de travail d'apprentissage automatique

Le Flux de travail d'apprentissage automatique comprend plusieurs étapes essentielles (Michelle 2001) ;

- 1) **Conception de l'étude** : Définir le problème, les objectifs et la question de recherche.

- 2) **Collecte de données** : Rassemblez des données pertinentes provenant de diverses sources.
 - 3) **Préparation des données** : Nettoyez, prétraitez et transformez les données.
 - 4) **Formation sur le modèle** : Adaptez le modèle aux données de formation.
 - 5) **Évaluation du modèle** : Évaluez les performances du modèle à l'aide de données de test.
 - 6) **Améliorer les performances** : Affinez le modèle et améliorez sa précision.
- Cette approche structurée garantit le développement et l'optimisation systématiques de modèles d'apprentissage automatique pour une résolution efficace des problèmes (Djelailia 2024).

Voici une représentation visuelle simplifiée du flux de travail d'apprentissage automatique (Figure III.5).



FIG III.5 FLUX DE TRAVAIL DE L'ETUDE SUR L'APPRENTISSAGE AUTOMATIQUE

III. 8 Les modèles d'apprentissage automatique

III. 8. 1 Les apprentissage d'ensembles

L'apprentissage d'ensemble est une technique d'apprentissage automatique qui consiste à combiner les prédictions de plusieurs modèles de base, souvent appelés 'apprenants faibles', pour obtenir un modèle plus précis et plus robuste. Cette approche permet de réduire la variance et le biais, améliorant ainsi la généralisation du modèle.

Ce principe s'appuie sur le 'crowdsourcing', qui postule que la combinaison statistique d'un grand nombre de jugements indépendants peut surpasser la précision d'un seul jugement, en réduisant les biais individuels et en augmentant la robustesse de la décision (Dietterich 2000).

III. 8. 1. 1 Concepts clés

a) **Diversité** : Une des principales hypothèses de l'approche d'apprentissage d'ensemble est que les modèles individuels seront diversifiés. De cette façon, les modèles feront différentes erreurs sur différentes parties de l'ensemble de données et offriront donc une diminution de la probabilité de surajustement tout en améliorant les performances de généralisation des modèles.

b) **Indépendance** : Plus précisément, chaque modèle composant un ensemble doit être aussi indépendant que possible. L'indépendance est importante, car elle signifie qu'une meilleure ou pire les performances d'un modèle n'influenceront pas les autres modèles, ce qui ne peut qu'augmenter la variété globale des prédictions données.

III. 8. 2 Types d'apprentissage d'ensemble

On peut citer trois grands types de méta-algorithmes qui visent à combiner des modèles de bas, comme l'algorithme de forêts aléatoires.

III. 8. 2. 1 Le Bagging (Bootstrap Aggregating)

Le bagging peut être décrit comme un type d'algorithme d'apprentissage d'ensemble dans lequel un certain nombre de modèles sont créés sur la base du même ensemble d'apprentissage mais avec un échantillonnage différent (Figure III.6). Les modèles individuels sont formés séparément, en utilisant souvent la même approche d'apprentissage fondamentale. La dernière prévision est calculée en combinant les prévisions de tous les modèles, en utilisant la moyenne ou le vote. Cette méthode est particulièrement utile pour réduire le surajustement dans les modèles à forte variance et faible biais, tels que les arbres de décision.

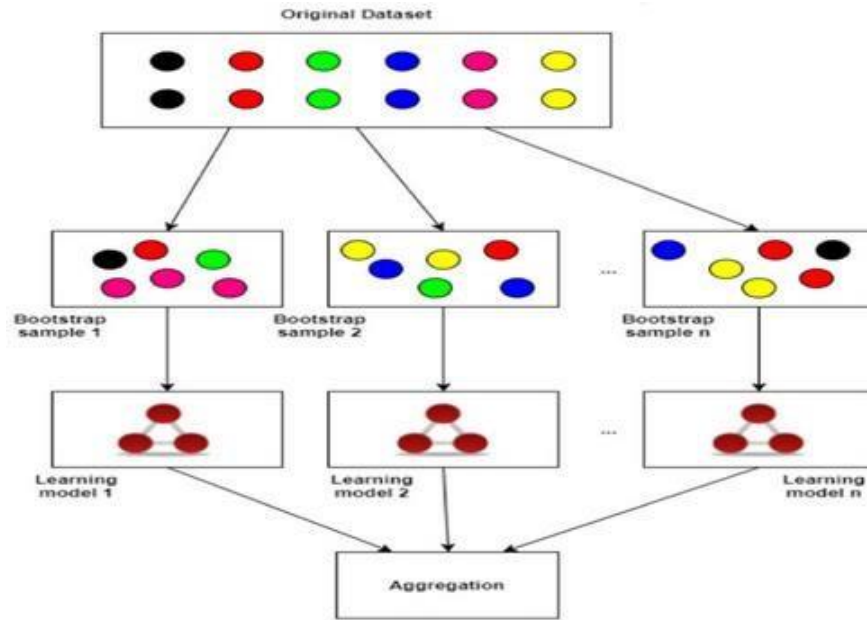


FIG III. 6 LA TECHNIQUE DE BAGGING

III. 8. 2. 2 Le Boosting

Un autre type d'apprentissage d'ensemble, dans lequel une série de modèles sont formés séquentiellement (Figure III.7), chacun fusionnant sur les erreurs du précédent. C'est à dire la manière d'entraîner le modèle d'ensemble en construction dépend des modèles de base précédents et plus particulièrement de leurs performances sur les données (Dietterich 2000). Cette stratégie itérative d'apprentissage utilisée s'adapte aux faiblesses des modèles de base précédents pour entraîner le modèle en construction, permet principalement d'obtenir un modèle d'ensemble avec un biais plus faible que ses composants : c'est pourquoi les modèles de base à faible variance mais les biais élevés sont bien adaptés pour le boosting.

Il existe plusieurs modèles qui se basent sur le principe de boosting avec différentes méthodes pour déterminer les poids. On peut citer en guise d'exemple : AdaBoost, Gradient Boost, Gradient Tree Boosting, XGBoost.


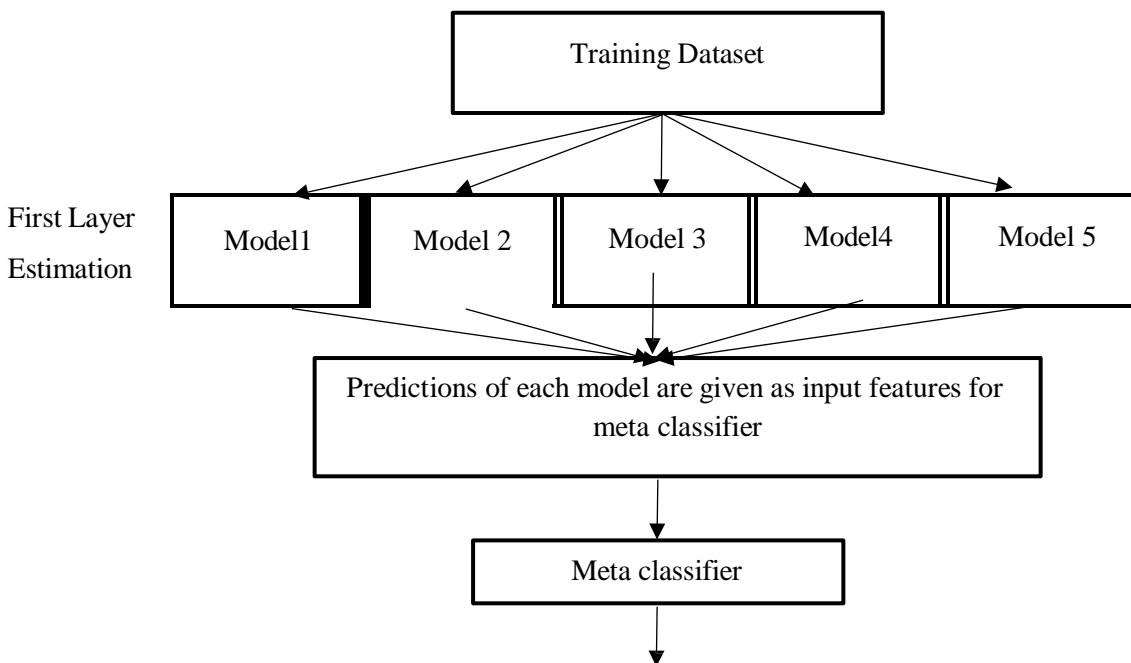


FIG III. 7 APPROCHE D'ENSEMBLE SEQUENTIELLE

III. 8. 2. 3 L'Empilement

l'empilement ou la généralisation empilée implique la formation de plusieurs modèles et la formation d'un méta-modèle (ou mélangeur), (Figure III.8).

Le méta-modèle apprend à combiner les modèles de base de manière à produire la meilleure prédiction finale (Dietterich 2000). L'empilement est généralement appliqué chaque fois que les classificateurs sont différents et que leurs forces complètent leurs faiblesses.






FIG III. 8 ARCHITECTURE D'EMPILEMENT

III. 9 Extreme Gradient Boosting (XGBoost)

XGBoost est un modèle de machine Learning basé sur l'apprentissage d'ensemble séquentiel XGBoost, développé par Tianqi Chen et Carlos Guestrin en 2016, est une implémentation optimisée de l'algorithme de Gradient Boosting. En s'appuyant sur des arbres de décision comme modèles de base, XGBoost se distingue par sa performance, sa flexibilité et sa capacité à traiter de grands ensembles de données.

III. 9. 1 Flux de travail de XGBoost

- 1) **Initialisation** : Le processus XGBoost commence par l'initialisation des paramètres du modèle, notamment le nombre de cycles de boosting, le taux d'apprentissage et la profondeur des arbres de décision.
- 2) **Formation** : Ensuite, XGBoost construit de manière itérative une série d'arbres de décision, chaque arbre apprenant à corriger les erreurs commises par ses prédécesseurs. Le modèle optimise un différentiable fonction de perte utilisant la descente de gradient, améliorant continuellement les performances prédictives.
- 3) **Régularisation** : XGBoost intègre des techniques de régularisation, telles que la régularisation L_1 et L_2 , pour éviter le surajustement et améliorer la généralisation du modèle. Cela garantit que le modèle capture des modèles significatifs dans les données sans mémoriser le bruit.
- 4) **Évaluation de l'importance des fonctionnalités** : Pendant la formation, XGBoost évalue l'importance de chaque fonctionnalité dans la prédiction de la variable cible. Ces informations aident les praticiens à identifier les facteurs clés

qui déterminent les prédictions du modèle et à prioriser la sélection des fonctionnalités.

5) Validation croisée et arrêt anticipé : XGBoost inclut une prise en charge intégrée de la validation croisée et de l'arrêt précoce (Figure III.9), permettant aux praticiens d'affiner efficacement les hyperparamètres du modèle et d'éviter le surajustement en surveillant les performances sur un ensemble de validation retenu (Chen et al 2016).

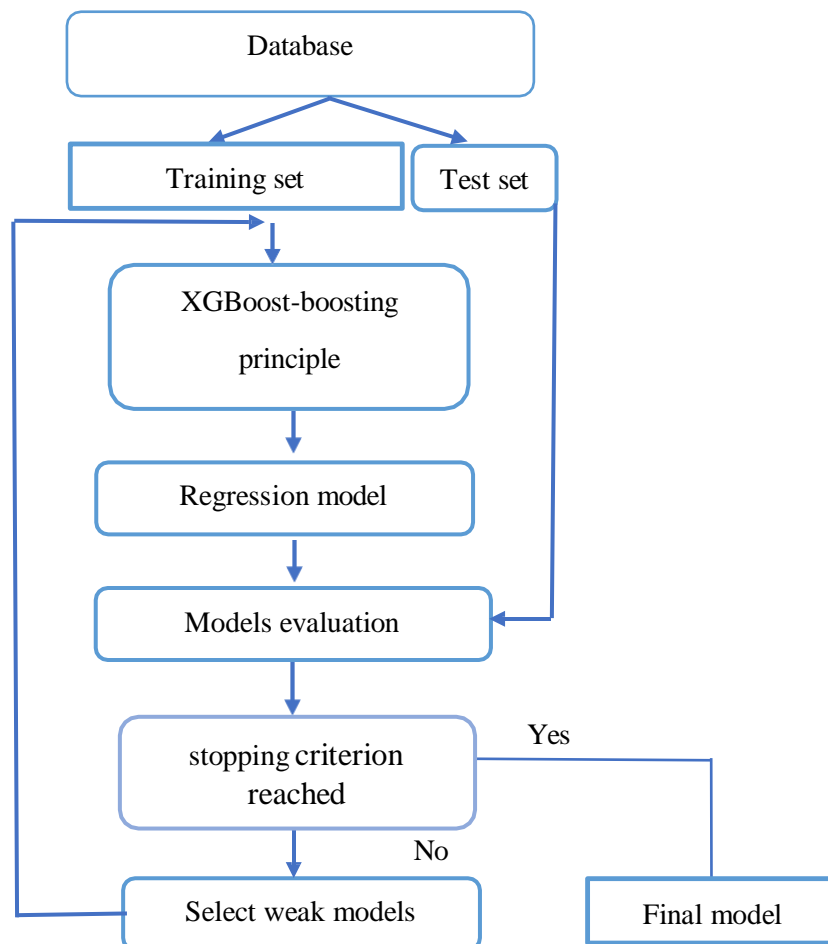


FIG III. 9 FLUX DE TRAVAIL DE L'ALGORITHME XGBOOST

III. 9. 2 Principales caractéristiques de XGBoost

a) Précision prédictive exceptionnelle : XGBoost offre des performances de pointe dans de nombreuses tâches d'apprentissage automatique de référence telles que la classification, la régression, le classement et les recommandations.

b) Efficacité et évolutivité : Une caractéristique distinctive de XGBoost est sa haute efficacité et son évolutivité, qui permettent de travailler avec de grandes quantités de données composées de millions d'échantillons et de fonctionnalités.

c) Robustesse au surapprentissage : XGBoost exploite en outre sa capacité anti-surajustement grâce à une régularisation de niveau supérieur et à un réglage de paramètres optimaux, avec la capacité de prédiction précise et stable sur les données invisibles et l'application dans le monde réel.

d) Interprétabilité et importance des fonctionnalités : L'une des fonctionnalités clés de XGBoost est l'importance des fonctionnalités, qui permet aux utilisateurs de mieux comprendre les résultats du modèle et de déterminer pourquoi les variables testées ont eu un impact significatif sur le résultat qui les intéresse. Ces niveaux de transparence améliorent l'explicabilité de la modélisation et soutiennent la prise de décision dans différents domaines.

III. 10 Les Random Forest (RF)

Les forêts aléatoires tirent leur nom de l'injection de hasard dans la construction des arbres pour s'assurer que chaque arbre est différent. Les arbres d'une forêt aléatoire sont randomisés de deux manières : en sélectionnant les points de données utilisés pour construire un arbre et en sélectionnant les caractéristiques de chaque test de division.

Les forêts aléatoires est l'algorithme le plus connu de la technique d'apprentissage ensembliste « bagging » ou « Bootstrap aggregating » qui consiste à créer plusieurs

entités d'un même modèle (plusieurs arbres de décisions) et d'entraîner chacun de ces arbres sur une portion aléatoire d'une collection de données, après avoir entraîné chaque arbre, nous pouvons regrouper les résultats de chaque arbre afin d'effectuer la prédiction, Random Forest est un algorithme d'apprentissage automatique populaire qui appartient à la famille des arbres de décision et peut être utilisé à la fois pour des problèmes de classification et de régression.

III. 10. 1 Flux de travail de Random Forest

L'algorithme de forêt aléatoire fonctionne en plusieurs étapes qui sont décrites ci-dessous (Figure III.10) :

1) Arbres de décision : Ces arbres sont comme des experts individuels, chacun se spécialisant dans un aspect particulier des données. Il est important de noter qu'ils fonctionnent de manière indépendante, minimisant ainsi le risque que le modèle soit trop influencé par les nuances d'un seul arbre.

2) Agrégation bootstrap (Bagging) : Random Forest s'appuie sur cette idée et introduit l'agrégation bootstrap également connue sous le nom de bootstrapping. En phase de formation, il crée plusieurs arbres de décision en utilisant un sous-échantillon sélectionné au hasard des données de formation avec remplacement. Cela signifie que chaque arbre individuel de la forêt est formé sur un ensemble de données quelque peu différent, ce qui ajoute encore plus de diversité.

3) Sélection aléatoire des fonctionnalités : La méthode de sélection aléatoire des fonctionnalités est également intégrée à Random Forest. Un nombre aléatoire de fonctionnalités (attributs) à chaque nœud de l'arbre de décision est utilisé et pris en compte pour les divisions. Cela contribue grandement à améliorer la diversité entre les arbres individuels et donc à minimiser les ajustements excessifs.

4) Vote ou calcul de moyenne : La dernière étape de la phase de prévision consiste à combiner les résultats de tous les arbres de décision de la forêt. Pour les tâches de classification, l'étiquette de classe la plus fréquemment choisie dans toutes les

arborescences est sélectionnée comme étiquette de classe. Dans les tâches de régression, l'importance de tous les arbres est prise en compte et le résultat final est la moyenne des valeurs de tous les arbres.




FIG III.10 ALGORITHME DE RANDOM FOREST

III. 10. 2 Principales caractéristiques de la forêt aléatoire

a) **Haute précision prédictive** : Random Forest est une procédure de prise de décision qui peut être visualisée comme un groupe de travailleurs examinant différents aspects du problème et prenant leurs décisions individuelles. Cela signifie que dans de nombreux cas, la capacité prédictive est supérieure à la prise de décision individuelle, car la réflexion du groupe dans son ensemble englobe un large éventail de stratégies pouvant être utilisées dans la prédiction.

b) **Résistance au surapprentissage** : Random Forest montre une résistance au surajustement car il encourage la coopération de ses arbres de décision au profit du point

de vue général. Au lieu de stocker toutes les spécificités des données d'entraînement, chaque arbre de décision a une position intermédiaire par rapport à ses voisins, évitant ainsi le surajustement lorsque l'on travaille avec des valeurs bruyantes ou aberrantes.

c) Gérer efficacement de grands ensembles de données : Dans le traitement de grands ensembles de données, Random Forest est efficace car les ressources nécessaires à la construction sont réparties entre plusieurs arbres de décision. Cela signifie que le traitement parallèle est effectué efficacement, élargissant l'espace de données pour permettre un développement de modèle et une prévision plus rapide dans de grands volumes de données.

d) Évaluation de l'importance variable : Random Forest, un peu comme un détective essayant de comprendre l'importance des indices les plus significatifs sur une scène de crime, utilise une approche systématique. En plus de fournir des mesures d'importance variable, cet algorithme permet aux praticiens de cibler les facteurs les plus susceptibles d'influencer les prédictions du modèle.

e) Validation croisée intégrée : Quant à Random Forest, il a géré un mécanisme de validation croisée dans lequel une partie des données de formation est utilisée pour des tests hors sac. Cette stratégie de validation permet d'établir la capacité du modèle à prédire l'exactitude des données invisibles, augmentant ainsi la fiabilité du modèle au-delà de l'ensemble de données d'entraînement.

f) Gestion des valeurs manquantes : La forêt aléatoire peut s'adapter à différents traitements des valeurs manquantes et utilise les informations disponibles pour faire des prédictions significatives. Random Forest évite de prendre des décisions hâtives lorsqu'un algorithme est incapable d'exploiter les probabilités de flou en conservant l'équilibre dans les processus de prise de décision lorsque des informations plus complètes ne sont pas disponibles.

g) Parallélisation pour une efficacité améliorée : Random Forest utilise des techniques de parallélisation pour optimiser la complexité temporelle des phases de

formation et de prédiction d'un modèle et exploiter avec succès les progrès actuels en matière de puissance de calcul. De cette manière, le travail peut être réparti à parts égales entre différents processeurs ou cœurs (Breiman 2001).

III. 11 Les réseaux de neurones

Un neurone est une cellule qui peut transmettre des informations à d'autres neurones grâce à ses différentes connexions (synapses). Le cerveau humain est le meilleur modèle d'une machine multifonctionnelle extrêmement rapide (Michelle 2001).

En général on peut dire que les réseaux de neurones peuvent être caractérisés comme des modèles de calculs apprenant, généralisant et organisant des données. Ils ne se programme jamais pour réaliser une ou telle tâche, il est entraîné sur des données acquises, grâce au mécanisme d'apprentissage qui agit sur les constituants du réseau afin de réaliser au mieux la tâche souhaitée.

III. 11. 1 Les connexions entre les neurones

La conception d'un réseau de neurones repose sur l'établissement de connexions entre ses unités de traitement. Ces connexions peuvent être de différents types, influant sur le comportement et les capacités du réseau (Zemouri 2003).

On distingue principalement quatre types de connexions :

- **Directes** : Ces connexions assurent le flux d'information de la couche d'entrée vers la couche de sortie, constituant ainsi le chemin le plus basique de propagation du signal.
- **Récurrentes** : Elles permettent à l'information de circuler de manière récursive au sein du réseau, créant des boucles de rétroaction. Cela est particulièrement utile pour modéliser des séquences temporelles ou des processus itératifs.

- **Latérales** : Ces connexions relient des neurones situés au même niveau, favorisant les interactions entre unités d'une même couche. Elles sont souvent utilisées dans les architectures compétitives pour permettre aux neurones de s'inhiber mutuellement et ainsi de sélectionner une réponse.
- **À délais** : Introduisant une notion de temps dans le réseau, ces connexions permettent de modéliser des systèmes dynamiques où l'état actuel dépend des états passés.

La connectivité entre les neurones peut être **complète** (chaque neurone d'une couche est connecté à tous les neurones de la couche suivante) ou **partielle** (les connexions sont plus restreintes, par exemple locales). La **localité** des connexions peut être exploitée pour réduire la complexité computationnelle et améliorer l'interprétation des résultats. Une **couche** dans un réseau de neurones est un ensemble organisé de neurones, qui effectuent généralement une transformation similaire sur les données qui les traversent.

III. 11. 2 Les réseaux de neurones artificiels

Un neurone artificiel Appelé aussi neurone formel est un modèle mathématique inspiré d'un neurone biologique, le neurone artificiel possède plusieurs entrées qui correspond aux dendrites où il recueille l'information et une sortie qui correspond au cône d'émergence (point de départ de l'axone) d'où il envoie un signal électrique (Figure III.11), Les actions excitatrices et inhibitrices des synapses sont représentées, la plupart du temps, par des coefficients numériques (les poids synaptiques) associés aux entrées. Les valeurs numériques de ces coefficients sont ajustées dans une phase d'apprentissage (Bourougaa et Seridi 2020). Dans sa version la plus simple, un neurone formel calcule la somme pondérée des entrées reçues et ajoute un biais, puis applique à cette valeur une fonction d'activation, généralement non linéaire. La valeur finale obtenue est la sortie du neurone (cite : [wikipedia.org/wiki/Neurone formel](https://fr.wikipedia.org/wiki/Neurone_formel)) comme montré dans l'équation suivante :

$$y_i = f(a_j) = \varphi\left(\sum_{i=0}^n (W_i * X_i) + b_j\right) \quad (\text{III. 4})$$

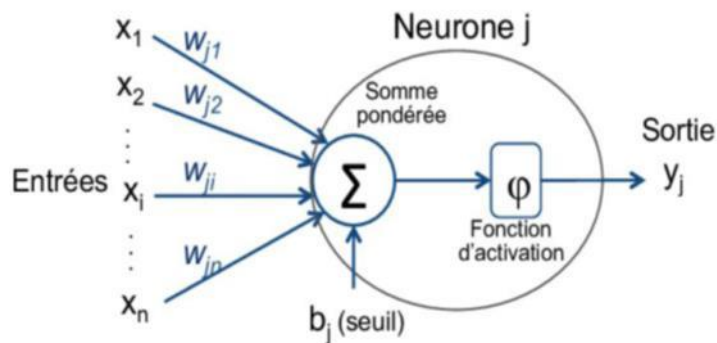


FIG III.11 SCHÉMA D'UN NEURONE ARTIFICIALE

1) Les poids et biais

Le poids est le coefficient qui control le signal d'entrée (la force de connexion), en d'autres termes le poids décide l'influence de l'entrée sur la sortie. Les poids sont mis à jour de façon continue par les réseaux de neurones artificiels pour améliorer la précision des sorties. Ce sont en réalité des valeurs d'auto-apprentissage. Dans le même ordre d'idées, le biais se connecte aux neurones de la couche précédente par l'intermédiaire d'un poids, généralement appelé seuil (cite : statsoft.fr/concepts-statistiques), les biais sont des paramètres additionnels utilisés dans les réseaux de neurones pour ajuster les valeurs d'entrées auxquelles les poids ont été appliqués, avant l'obtention de valeurs de sorties définitives. Elles influencent le comportement de la fonction d'activation.

2) La fonction d'activation

La fonction d'activation est une fonction mathématique responsable du type de l'information émise par le neurone, elle intervient après le calcul de la somme

pondérée et l'ajout du biais, c'est-à-dire s'active lorsque la valeur calculée atteint le seuil requis fixé.

Les fonctions d'activation occupent une place importante dans le processus d'apprentissage et d'amélioration continue des neurones artificiels.

Plusieurs fonctions d'activation peuvent être présentes dans un réseau de neurones comme la fonction sigmoïde, l'unité linéaire rectifiée (ReLU), souvent utilisée dans les couches cachées, la fonction Soft max, utilisée dans la couche de sortie, et la fonction de tangente hyperbolique $\tanh(x)$.

III. 11. 3 Architectures de réseaux de neurones Artificiels

L'organisation des réseaux de neurones peut se faire à partir de deux grandes catégories d'architecture : les réseaux statiques et les réseaux dynamiques.

III. 11. 3. 1 Réseaux statique (non bouclés)

Un réseau est non bouclé, ou statique, si son graphe ne possède pas de cycle (Figure III.12). Il réalise donc, de manière générale, une relation algébrique non linéaire entre ses entrées et ses sorties.

C'est à dire qu'il est obligatoire de représenter un réseau graphiquement par un ensemble de neurones connectés entre eux et que l'information circule des entrées vers les sorties sans retour (un seul sens), la sortie courante n'a aucune influence sur les entrées futures. Donc à partir d'un neurone Quelconque, en suivant les connexions, on ne peut pas revenir au neurone de départ (Dreyfur 2004), (ROUANE et al 2019).




FIG III. 12 UN RESEAU DE NEURONE NON BOUCLE

III. 11. 3. 2 Réseaux dynamique (bouclés)

Les réseaux bouclés (ou récurrents ou encore dynamiques) permettent des connexions arbitraires entre les neurones de toutes les couches (Figure III.13) ; lorsqu'on se déplace dans le réseau en suivant le sens des connexions, il est possible de trouver au moins un chemin qui revient à son point de départ. La sortie d'un neurone du réseau peut donc être fonction d'elle-même ; cela n'est évidemment concevable que si la notion de temps est explicitement prise en considération. Il peut avoir plusieurs topologies (Benahmed, 2002). Parmi les architectures de cette classe ; le réseau de neurones à mémoires (MNN) et le réseau neuronal récurrent à temps discret (DTRNN) (Rouane et al 2019).




FIG III.13 UN RESEAU DE NEURONE BOUCLE

III. 11. 4 Types des réseaux de neurones artificiels (RNA)

On fait appel à différentes structures de réseaux de neurones artificiels en fonction de la méthode d'apprentissage utilisée et de l'objectif recherché.

III. 11. 4. 1 Perceptron

À l'origine, la forme la plus simple de réseau neuronal artificiel était composée d'un seul neurone modifié par des pondérations et doté d'une valeur seuil. Désormais, le terme « Perceptron » désigne aussi les réseaux à propagation avant à couche unique.

III. 11. 4. 2 Réseaux de neurones à propagation avant

Un réseau de neurones artificiels à propagation avant ne peut transmettre l'information que dans un unique sens de traitement. Il n'y a pas de cycles ou de boucles dans le réseau, les réseaux peuvent être monocouches, c'est-à-dire constitués uniquement de couches d'entrée et de sortie, ou multicouches (MLP) est largement utilisé dans l'apprentissage automatique (machine learning) pour effectuer des tâches telles que la classification et la régression.

Le MLP est un réseau de neurones qui se compose de plusieurs couches de neurones reliées entre elles. Chaque couche est composée de plusieurs neurones. La première couche est appelée la couche d'entrée, qui reçoit les données en entrée. Les couches

intermédiaires sont connues sous le nom de couches cachées, car leurs valeurs ne sont pas directement observées. Enfin, la dernière couche est la couche de sortie, qui génère la sortie finale du réseau (Figure III.14). Il est souvent entraîné sur un ensemble de données d'entraînement et testé sur un ensemble de données de test distinct pour évaluer sa performance (Hornik et al 1989).

Le MLP utilise une fonction d'activation non linéaire pour chaque neurone. Les fonctions d'activation les plus couramment utilisées sont la fonction sigmoïde, la fonction ReLU (rectified linear unit), la fonction tan h (tangente hyperbolique), et la fonction soft max (pour la classification).

Le MLP a été introduit dans les années 1980 et est toujours largement utilisé aujourd'hui en raison de sa simplicité, de sa capacité à modéliser des relations non linéaires complexes, et de sa bonne performance sur de nombreuses tâches d'apprentissage automatique.




FIG III. 14 UN PERCEPTRON MULTICOUCHE CONTENANT TROIS COUCHES

III. 11. 4. 3 Réseaux de neurones récurrents (RNN)

Dans les réseaux de neurones récurrents, il est possible de faire passer l'information dans des boucles de rétroaction, et ainsi de la faire revenir vers une couche précédente. Ces rétroactions permettent au système de se constituer une mémoire.

Un réseau de neurones récurrent (RNN) est un type de réseau de neurones artificiel qui utilise des données séquentielles ou des données de séries temporelles. Ces algorithmes d'apprentissage en profondeur sont couramment utilisés pour des problèmes ordinaux ou temporels, tels que le traitement du langage naturel, le sous-titrage d'images ; ils sont incorporés dans des applications populaires telles que la recherche vocale et Google Translate. Les réseaux de neurones récurrents utilisent des données d'entraînement pour apprendre (Shahin et al, 2008). Ils se distinguent par leur « mémoire » car ils prennent des informations d'entrées antérieures pour influencer l'entrée et la sortie en cours, la sortie des réseaux de neurones récurrents dépend des éléments antérieurs au sein de la séquence. Alors que les événements futurs seraient également utiles pour déterminer la sortie d'une séquence donnée, les réseaux de neurones récurrents unidirectionnels ne peuvent pas rendre compte de ces événements dans leurs prédictions.

Le schéma suivant (Figure III.15) montre le détail d'une couche récurrente. Les x_j^t et les y_j^t désignent respectivement les entrées et les sorties de la couche à l'instant t .

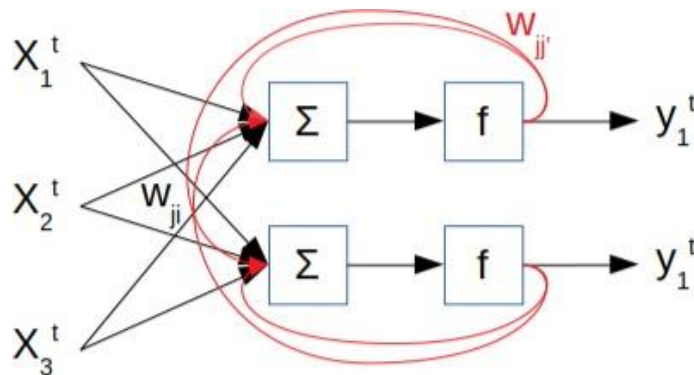


FIG III.15 UNE COUCHE RNN SIMPLE A TROIS ENTREE ET DEUX SORTIES. LES CONNEXIONS RECURRENTES NOTEES EN ROUGE

Remarquons la présence de poids w_{ji} reliant les entrées à la sortie, et la présence de poids $w_{jj'}$ entre la sortie et l'entrée de la couche, qui sont les fameuses connexions récurrentes (en rouge).

III. 11. 4. 4 Réseaux de neurones convolutifs (CNN)

Le réseau de neurones convolutifs appelé (CNN : Convolutional Neural Network) est un type de réseau de neurones artificiels acyclique (feed-forward) conçu en matière de reconnaissance d'images pour travailler avec des données d'images bidimensionnelles, bien qu'ils puissent être utilisés avec des données unidimensionnelles et tridimensionnelles. Ces réseaux sont capables d'apprendre à extraire des caractéristiques locales, c'est-à-dire des structures qui se répètent à travers l'image (Phung et al, 2019). Au centre du réseau de neurones convolutifs se trouve la couche convolutionnelle qui donne son nom au réseau. Cette couche effectue une opération appelée « convolution » est la simple application d'un filtre à une entrée qui entraîne une activation. L'application répétée d'un même filtre à une entrée produit une carte d'activations appelée carte de fonctionnalités (Feature map), indiquant les emplacements d'une fonctionnalité détectée dans une entrée, telle qu'une image (Figure III.16).




FIG III.16 ARCHITECTURE STANDARD D'UN RESEAU DE NEURONE A CONVOLUTION CNN

0

III. 11. 5 Flux de travail d'un réseau de neurones

1) **La collecte d'une base de données** : Le but de cette étape est de collecter suffisamment de données pour créer une base de données représentative qui sera

utilisée pour former et tester le réseau neuronal. La base de données est l'entrée du réseau neuronal, par conséquent, elle détermine la taille du réseau et les performances du système.

2) Divisez la base de données : Après avoir collecté suffisamment de données, il est nécessaire de commencer à diviser les données en deux phases, l'une pour l'apprentissage et l'autre pour les tests, afin de pouvoir contrôler la phase d'apprentissage, vérifier le réseau obtenu et déterminer ses performances.

En règle générale, lorsque nous divisons les données en partie apprentissage et partie test, la sélection sélectionne les données au hasard pour garantir que les partitions de test et de formation répondent aux exigences.

3) Le prétraitement des données : Trois procédures de prétraitement des données seront exécutées pour former le RNA plus efficacement. Ces processus sont : la résolution du problème de la perte de données, la normalisation et la randomisation des données. Les données manquantes seront remplacées par la moyenne des valeurs adjacentes dans la même semaine. Le processus de normalisation avant de présenter les données d'entrée au réseau est généralement une bonne habitude.

4) Choix de l'architecteur : Un réseau de neurones artificiels (Modèle) est un modèle non linéaire qui utilise une structure qui peut décrire tout complexe non linéaire lié à l'entrée et à la sortie. Les neurones sont reliés par des liens appelés synapses, et chaque synapse a un facteur de pondération. La somme pondérée du signal d'entrée peut être exprimée sous la forme d'une relation mathématique.

5) Phase d'apprentissage : Est une étape du développement des réseaux neuronaux. A ce stade, le comportement du réseau va évoluer jusqu'à obtenir le comportement souhaité. L'idée est d'ajuster le poids du RN pour réduire les échantillons d'apprentissage erronés, c'est-à-dire pendant le processus de formation, ajustez les pondérations pour rendre la sortie réelle (prévue) proche de la sortie cible (mesurée) du réseau. Les réseaux de neurones artificiels apprennent en utilisant des

algorithmes d'apprentissage automatique, tels que la descente de gradient. L'algorithme de descente de gradient permet d'ajuster les poids de chaque connexion entre les neurones en fonction de la performance du réseau sur une tâche donnée qui peut être une prédiction ou une classification.

6) Mesurez les performances du réseau neuronal sur la base du test : Les Performances du modèle ANN considéré sont évaluées à l'aide de méthodes largement utilisées dans les scores d'évaluation (Phung et al, 2019), telles que l'erreur quadratique moyenne (RMSE), l'erreur de biais moyenne (MBE), l'erreur en pourcentage absolue moyenne (MAPE) et le coefficient de corrélation (R).

III. 11. 6 Principales caractéristiques d'un réseau de neurones

a) **Auto-apprentissage** : C'est la principale caractéristique des réseaux de neurones artificiels, qui sont si populaires auprès des programmeurs et des hommes d'affaires du monde entier. Vous créez simplement un algorithme de base, puis lui donnez des exemples à former (par exemple, des photos de personnes, si vous voulez que votre réseau de neurones recherche des personnes sur une photo) et regardez les résultats. Dans le même temps, l'algorithme lui-même décide comment atteindre l'objectif souhaité, trouvant souvent des solutions qui ne sont pas évidentes (pour les gens).

De plus, le réseau de neurones n'est pas seulement un auto-apprentissage, il est conçu pour s'auto-apprendre en permanence et améliorer ses résultats. Une fois le système formé, le programme ou l'application devient plus convivial au fur et à mesure de son utilisation. C'est pourquoi le système de recommandation de Google Translate, Netflix ou TikTok s'améliore chaque année.

b) Filtrage efficace du bruit dans les données : Imaginez n'importe quel endroit raisonnablement bruyant, comme un marché ou un stade. Les gens parlent, la musique joue fort, les voitures passent quelque part et les oiseaux crient, il y a du bruit partout, mais malgré cela, vous pouvez communiquer calmement avec les personnes à proximité. Vos oreilles captent des tonnes de sons inutiles, mais votre cerveau les filtre et ne perçoit que ce que dit votre interlocuteur. Cette propriété se retrouve également dans les réseaux de neurones artificiels. Après la formation, ils sont capables d'isoler uniquement les informations dont ils ont besoin à partir d'un énorme flux continu de données, en ignorant tout bruit parasite.

Il s'agit d'une fonctionnalité très utile si vous avez besoin de rechercher des modèles dans d'énormes quantités de données hétérogènes, telles que la recherche médicale non clinique, les prévisions météorologiques, l'analyse du marché économique ou la traduction de texte.

c) S'adapter au changement : Des réseaux de neurones artificiels est la capacité de s'adapter aux changements dans les données d'entrée. Par analogie, nous pouvons donner un exemple avec la mise à jour des applications. Disons que vous êtes hors ligne depuis longtemps et pendant ce temps, Instagram et TikTok ont été mis à jour avec quelques nouvelles fonctionnalités. Après avoir pris quelques minutes pour lire les instructions, vous serez familiarisé avec toutes les nouvelles fonctionnalités et continuerez à utiliser Instagram et TikTok. La même chose se produira avec les réseaux de neurones. Après une courte période d'adaptation aux changements, il continuera à fonctionner avec la même efficacité.

d) Tolérance aux pannes : Les solutions basées sur les réseaux de neurones restent opérationnelles même après la défaillance d'une partie des neurones. Oui, cela peut affecter la précision et/ou la vitesse de l'algorithme, mais ses réponses seront toujours logiques, rationnelles et correctes. C'est une propriété très utile si un appareil

avec un réseau de neurones embarqué doit fonctionner dans un environnement agressif (zones radioactives, en temps de guerre, dans des bâtiments ou de l'espace détruits).

e) **De belles opportunités** : Leur large éventail d'applications. Les réseaux de neurones fonctionnent comme un cerveau humain, ce qui signifie qu'une fois entraînés, ils peuvent effectuer diverses tâches dans divers domaines, allant de l'augmentation des conversions dans une boutique en ligne à la recherche de planètes semblables à la Terre dans l'espace. L'essentiel est qu'il existe suffisamment d'ensembles de données réelles ou synthétiques pour la formation.

f) **Vitesse de travail** : Leur vitesse énorme, à la fois par rapport aux algorithmes informatiques conventionnels et par rapport au cerveau humain. Les réseaux de neurones artificiels ne se fatiguent pas et n'ont pas de pause déjeuner. La vitesse de leur travail n'est déterminée que par la puissance de calcul dont ils disposent (carte vidéo, serveur cloud ou centre de données). Cela signifie généralement qu'ils émettent une solution presque instantanément.

III. 12 Conclusion

Dans ce chapitre, nous avons présenté les principes fondamentaux de l'apprentissage automatique, largement utilisés pour modéliser des systèmes complexes. La conception et l'entraînement d'un modèle d'apprentissage automatique dépendent fortement des modèles de base explorés précédemment, notamment de leurs performances sur les données.

Pour nos modèles de base, nous avons considéré les techniques d'exploration de données et de décisionnel.

Parmi la vaste gamme de méthodes d'apprentissage automatique adaptées aux problèmes d'optimisation géotechnique, nous avons choisi d'explorer **les ensembles d'apprentissage**. Plus spécifiquement, nous nous concentrerons sur les techniques les mieux adaptées à notre problème et à la disponibilité de nos données : **l'Extreme**

Gradient Boosting (XGBoost), les forêts aléatoires (Random Forest) et les réseaux de neurones artificiels (RNA).

Nous avons approfondi les bases théoriques de ces algorithmes, leur fonctionnement et les paramètres clés à ajuster pour obtenir des modèles performants.

Chapitre IV

**Position du problème et
Méthodologie de calcul**

IV.1 Introduction

La reconnaissance d'une zone instable commence d'abord par l'exploitation des documents bibliographiques tels que les cartes géographiques, les cartes topographiques, les photographies aériennes...etc. Mais ces données restent insuffisantes car elles nous renseignent seulement sur les affleurements de surface, donc il faut compléter ces données par des campagnes de reconnaissance « in situ » et des essais au laboratoire qui interviennent comme moyens indispensables permettant de fournir des renseignements sur la nature lithologique des différentes couches, d'apprécier leurs homogénéités et d'estimer leurs caractéristiques physique et mécanique.

L'objectif de cette étude est l'analyse de la stabilité d'un talus de site de glissement, en simulant le comportement réel du terrain par l'utilisation d'une loi de comportement approprié afin de déterminer le facteur de sécurité, dont en utilisant le logiciel de calcul par éléments finis Plaxis 2D. Ensuite, une validation de la méthode d'optimisation proposée a pour objectif de calibrer le modèle de Mohr Coulomb, à partir des résultats de glissement de talus. Il s'agit de tester les méthodes d'optimisations tel que la méthode de Taguchi et la méthode de la surface de réponse (RSM) sans être gêné par des erreurs expérimentales ou de modélisation d'une part.

D'une autre part, nous explorerons les applications des techniques de l'apprentissage automatique qu'est présenté comme une sous-discipline de l'intelligence artificielle telles que Extreme Gradient Boosting (XGBoost) et la forêt aléatoire (RF) de plus la méthode des réseaux de neurones artificiels (RNA), de façon d'intégrer l'analyse des données numériques dans un système d'évaluation de la sécurité et de la stabilité des pentes basé sur ces techniques est de trouver la combinaison optimale de facteurs d'entrée de pente.

Maintenant que le contexte de l'étude est posé, la méthode d'optimisation par Taguchi et la surface de réponse (RSM) déjà présentées au chapitre II sont testées, afin d'en définir plus précisément le fonctionnement par l'optimisation des trois paramètres de la loi de Mohr Coulomb, la cohésion C et de l'angle de frottement φ , le module E_{ref} , à partir de la modélisation de talus. Pour la méthode de l'intelligence artificielle nous avons ajouté le paramètre de volume de remblai V .

IV.2 Reconnaissance du site

Le secteur d'étude est situé au lieu-dit 42^{ème}, soit à 44.5Km du chef-lieu de la wilaya de Béjaia, sur la RN12 traversant une zone montagneuse à pentes raides de la région d'Adekar (Figure IV.1). Le site de point de vue géomorphologique est une surface topographique inclinée, situé le long d'un versant accidenté, ayant une pente élevée, traversé par divers accidents, raviné par plusieurs thalwegs et confiné entre deux massifs (grés, marnes gréseuses) (Figure IV.2). Dans lesquelles sont interstratifiées des marnes schisteuses altérées et friables, Les grés forment tantôt des entablements horizontaux, tantôt des arêtes et des parois très déchiquetées. Les marnes et grés mis en place à l'Oligocène ont subi au Quaternaire des phénomènes d'altération et d'érosion qui ont abouti à combler les dépressions par des dépôts de produits argileux très graveleux et blocs (Figure IV.3). La zone étudiée se trouve dans une zone à risque sismique zone II-a (sismicité faible). Le réseau hydraulique est constitué de cours d'eau temporaires alimentés par de nombreux torrents le long des pentes de montagnes. Les pentes naturelles du site, sont suffisantes pour drainer les eaux de pluies quelle que soit l'intensité des averses, seuls quelques replats topographiques et les assiettes de terrassement favorisent la stagnation des eaux.

L'étude de cas concerne un talus de site de glissement est localisé sur la RN 12 au PK 119+000 à mi-hauteur du versant doté de pentes moyennes à élevées et présentant une

topographie irrégulière. Il est situé à proximité de l'intersection menant vers le village Acif El Hammam qui s'est manifesté sur une longueur de 300m et une largeur de 280m et qui est traversé par un thalweg large et profond.

Les calculs sont effectués sur les profils de terrain considérés comme représentatifs (Figure IV.4). Les caractéristiques mécaniques adoptées dans cette étude de stabilité sont obtenues à partir d'essais en laboratoire et sur le terrain (Tableau IV. 1).

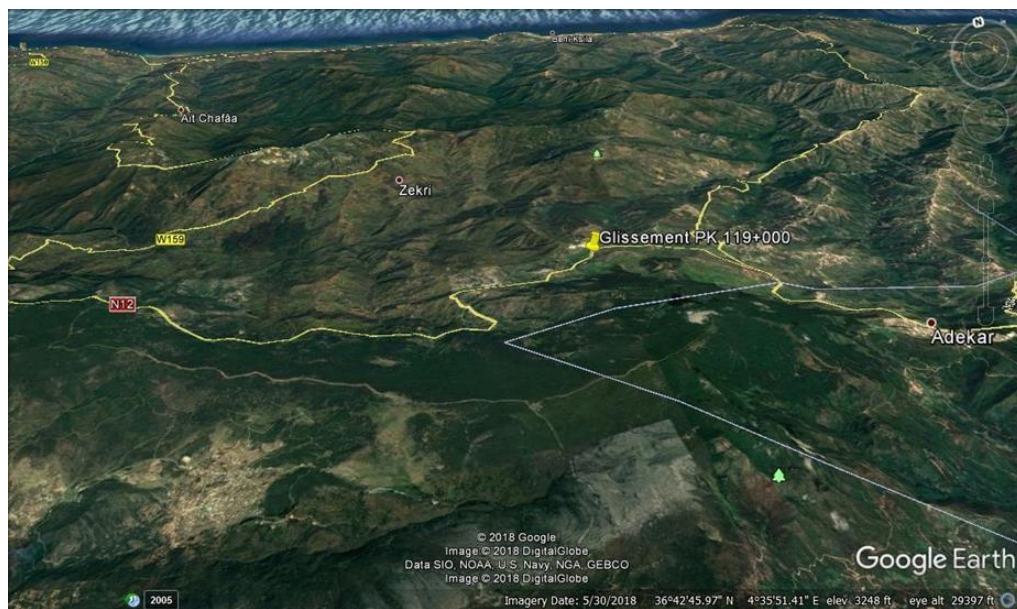


FIG IV.1 SITUATION GENERAL DU SITE



FIG IV.2 SITUATION DETAILLEE DU SITE DU GLISSEMENT

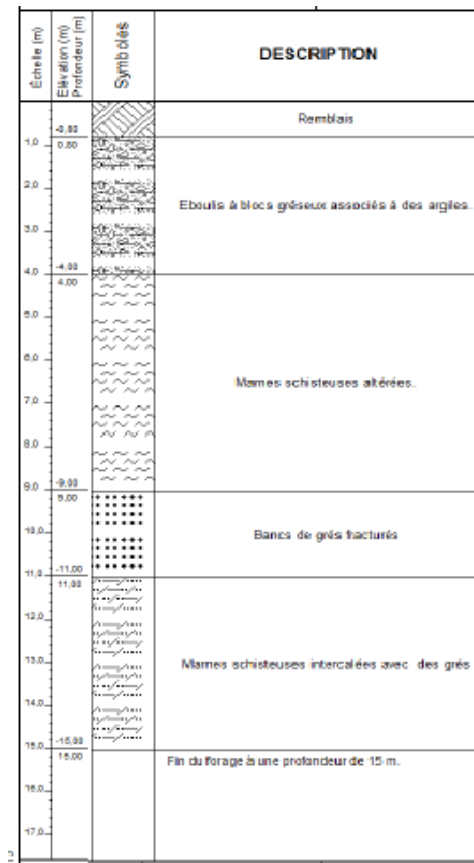


FIG IV.3 COLONNE STRATIGRAPHIQUE DU SEDIMENT FORMATIONS QUI CONSTITUENT LA PENTE

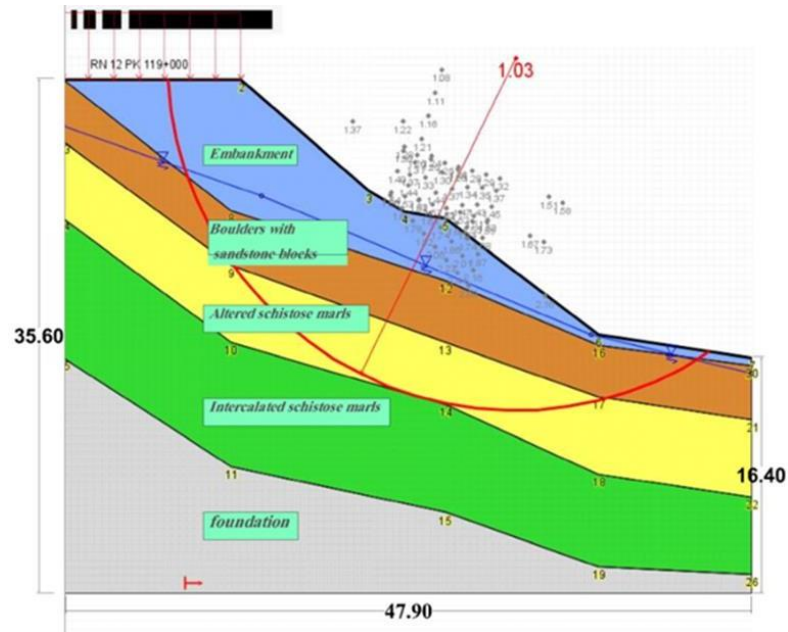


FIG IV.4 GEOMETRIE DU TALUS

TABLEAU IV.1 PROPRIETES DES COUCHES DE SOL

Sol	γ (kN/m ³)	E(kN/m ²)	ϕ (°)	C(kN/m ²)
Remblai	20,00	1.5 E+5	30	15
Eboulis à blocs gréseux	20,10	4.7 E+5	38	33
Marnes schisteuses altérées	20,20	4.2 E+5	15	60
Marnes schisteuses intercalées	21,20	5.8 E+5	20	500
Fondation	21,20	5.8E+5	20	500

IV. 3 Méthodologie de L'optimisation

Dans notre cas, nous avons étudié l'effet de la variation des propriétés mécaniques et géométriques sur le facteur de sécurité.

Le facteur de sécurité a été calculé à l'aide de la technique de réduction phi disponible dans Plaxis2D, dans laquelle les paramètres de résistance au cisaillement sont réduits

par étapes jusqu'à la rupture du corps de sol, comme le montre l'équation IV.1 (Plaxis Reference Manual 2002).

$$\Sigma MSF = \frac{\tan\phi_{input}}{\tan\phi_{reduced}} = \frac{C_{input}}{C_{reduced}} \quad (IV.1)$$

Ou ;

ϕ_{input} : la valeur d'entrée de l'angle de frottement interne ($^{\circ}$)

$\phi_{reduced}$: la valeur réduite de l'angle de frottement interne à la rupture ($^{\circ}$)

C_{input} : la valeur d'entrée de la cohésion (kPa)

$C_{reduced}$: la valeur réduite de la cohésion à la rupture (kPa).

IV. 3. 1 Modélisation Numérique

La figure IV.5 montre le maillage par éléments finis du modèle. Pour le calcul de stabilité, nous avons modélisé numériquement ce talus, à l'aide du logiciel éléments finis bidimensionnel Plaxis2D version 8.2, avec un problème de déformation plane et un comportement à long terme en utilisant des conditions d'analyse drainées et le modèle de Mohr-Coulomb. Le modèle nécessite cinq paramètres d'entrée de base : le module d'Young E, le coefficient de Poisson ν , la cohésion C, l'angle de frottement ϕ et l'angle de dilatance ψ . Quinze (15) éléments triangulaires noués sont utilisés pour générer un maillage d'éléments finis de densité appropriée, la densité de maillage moyenne est adoptée globalement. Les limites gauche et droite du modèle ont été fixées dans le sens horizontal tandis que la limite inférieure a été fixée dans toutes les directions.

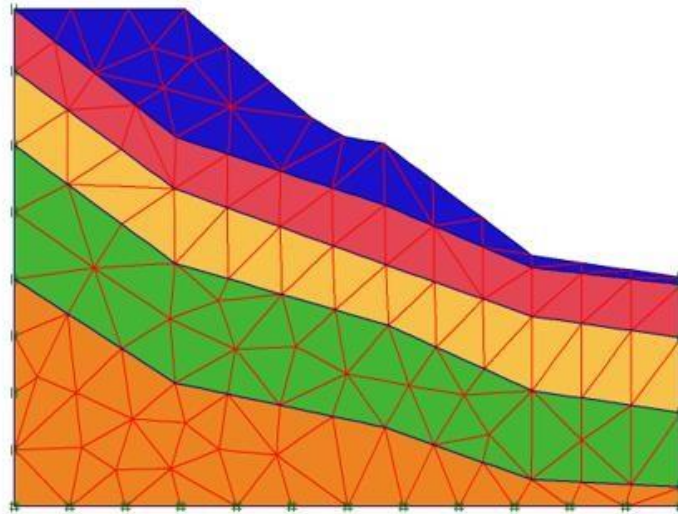


FIG IV.5 MAILLAGE PAR ELEMENTS FINIS DU MODELE ETUDIE 0

IV. 3. 2 Application des Méthodes d'Optimisation

IV. 3. 2. 1 la Méthode de Taguchi

Le processus d'optimisation de la méthode Taguchi a été réalisé à l'aide de Minitab 18, un logiciel utilisé pour l'analyse statistique et la résolution de problèmes et l'amélioration de la qualité dans le domaine des mathématiques, des statistiques, de l'économie et de l'ingénierie.

Le but de ce processus est d'obtenir une combinaison optimale de paramètres de facteurs de contrôle qui atteignent la robustesse contre les facteurs de bruit. La disposition du tableau orthogonal (L27) a été traitée, elle se composait de 27 combinaisons utilisant trois variables de processus prises chacune à trois niveaux afin d'obtenir une conception stable.

Pour sélectionner un tableau orthogonal approprié pour les expériences, les degrés de liberté totaux doivent être calculés. Les degrés de liberté sont définis comme le nombre de comparaisons entre les paramètres de processus qui doivent être faites pour déterminer quel niveau est le meilleur et en particulier combien il est meilleur (Alexis 1995).

IV. 3. 2. 1. 1 base des données

Afin d'obtenir une conception optimale, il faut tout d'abord choisir les facteurs et leurs niveaux de variation. Dans notre étude nous considérons trois (3) facteurs : la cohésion(c), l'angle de frottement (ϕ) et le module E_{ref} . Affectons trois (3) niveaux à chacun d'entre eux. Ces facteurs et leurs niveaux sont présentés dans le tableau IV.2.

TABLEAU IV.2 PARAMETRES D'ENTREE ET LEURS NIVEAUX

°	Paramètres	Unité	Niveau1	Niveau2	Niveau3
1	C	kN/m ²	05	15	50
2	ϕ	Degré (°)	30	35	40
3	E_{ref}	kN/m ²	500	10000	15000

TABLEAU IV.3 MATRICE ORTHOGONALE STANDARD L27 DE TAGUCHI

Simulation N°	Facteurs de Contrôle		
	C	ϕ	E_{ref}
1	1	1	1
2	1	2	1
3	1	3	1
4	1	1	2
5	1	2	2
6	1	3	2
7	1	1	3
8	1	2	3
9	1	3	3
10	2	1	1
11	2	2	1
12	2	3	1
13	2	1	2
14	2	2	2
15	2	3	2
16	2	1	3

17	2	2	3
18	2	3	3
19	3	1	1
20	3	2	1
21	3	3	1
22	3	1	2
23	3	2	2
24	3	3	2
25	3	1	3
26	3	2	3
27	3	3	3

Le tableau IV.3 montre la matrice orthogonale standard L27. L'équation S / N dépend du critère de la caractéristique de qualité à optimiser, l'approche « Plus petit est mieux » a été choisie pour cette analyse comme indiqué dans l'équation IV.2.

Dans le concept de « plus il est petit, plus c'est mieux », le rapport S / N utilisé pour ce type de réponse est donné par :

$$\frac{S}{N} (dB) = -10 \log \left(\frac{1}{n} \sum_{i=1}^n y_i^2 \right) \quad (IV. 2)$$

Les rapports S / N sont exprimés sur une échelle de décibels et y_i est la valeur de réponse pour une condition d'essai répétée n fois.

Taguchi utilise des rapports signal sur bruit comme mesures de performance pour optimiser la variable de réponse ou la caractéristique de qualité de sortie contre les variations des facteurs de bruit. Les rapports signal / bruit de Taguchi, qui sont des fonctions logarithmiques de la sortie souhaitée, s'adaptent comme des fonctions objectives pour l'optimisation, servent à l'analyse des données et présagent un résultat optimal (Sudhakara et al 2014).

Sur la base des exécutions de simulation, le facteur de sécurité a été enregistré à trois niveaux différents et la valeur moyenne est prise pour analyse. Le tableau suivant montre les réponses mesurées et les rapports (S/N) atteints.

IV. 3. 2. 1. 2 Résultats et interprétations

TABLEAU IV.4 REPONSES MESUREES ET RAPPORTS S/N POUR LE MODEL PRINCIPALE

N°	Facteurs d'entrées			Variable de repense F_s	Rapport S/N
	C	Φ	E_{ref}		
1	5	30	500	1,067	-0,563
2	5	35	500	1,245	-1,903
3	5	40	500	1,334	-2,503
4	5	30	10000	1,065	-0,546
5	5	35	10000	1,238	-1,854
6	5	40	10000	1,314	-2,371
7	5	30	15000	1,068	-0,571
8	5	35	15000	1,238	-1,854
9	5	40	15000	1,32	-2,411
10	15	30	500	1,332	-2,490
11	15	35	500	1,33	-2,477
12	15	40	500	1,334	-2,503
13	15	30	10000	1,325	-2,444
14	15	35	10000	1,33	-2,477
15	15	40	10000	1,334	-2,503
16	15	30	15000	1,325	-2,444
17	15	35	15000	1,33	-2,477
18	15	40	15000	1,334	-2,503
19	50	30	500	1,357	-2,651
20	50	35	500	1,357	-2,651
21	50	40	500	1,364	-2,696
22	50	30	10000	1,361	-2,677
23	50	35	10000	1,366	-2,709
24	50	40	10000	1,373	-2,753
25	50	30	15000	1,361	-2,677
26	50	35	15000	1,366	-2,709
27	50	40	15000	1,372	-2,747

À l'aide de Minitab, chaque paramètre de sortie est analysé statistiquement et les principaux tracés d'effets des rapports signal / bruit (S/N) pour les mesures de sortie sont obtenus.

Les résultats d'analyse de Taguchi L27 pour l'estimation du potentiel de coefficient de sécurité (F_s) sont indiqués au graphique des effets principaux pour les moyennes et le rapport S/N figure IV.6 et IV. 7 respectivement.




FIG IV.6 COURBES DES EFFETS PRINCIPAUX POUR LES RAPPORTS S / N




FIG IV.7 GRAPHIQUE DES EFFETS PRINCIPAUX POUR LES MOYENNES

Ces graphiques sont utilisés pour déterminer le paramètre de conception optimal à partir d'influence des divers paramètres d'entrées pour obtenir la condition de stabilité optimale (Ranganath et al 2015), Ils montrent la variation de la réponse individuelle avec trois paramètres séparément. Dans le graphique, l'axe des x représente la valeur de chaque paramètre de processus et l'axe des y est la valeur de la réponse. La ligne horizontale indique la moyenne de la réponse.

Si la ligne d'un paramètre est presque horizontale, le paramètre n'a aucun effet significatif. En revanche, un paramètre pour lequel la ligne a la plus forte inclinaison a l'effet le plus significatif (Seitz et Grabe 2016). Dans ce cas, la cohésion a la plus grande influence sur la stabilité, suivi de l'angle de frottement.

Par ailleurs, il ressort clairement de la figure IV.6 que le facteur de sécurité minimum est atteint grâce à la combinaison des paramètres de commande 5 kN/m^2 , 30° et 10000 kN/m^2 qui représentent respectivement la cohésion, l'angle de frottement et E_{ref} . La combinaison optimale (A1-B1-C2) a été sélectionnée avec le rapport signal/bruit le plus élevé.

TABLEAU IV.5 REPONSES POUR LE RAPPORT SIGNAL /BRUIT « PLUS PETIT EST MIEUX»

Niveau	C	φ	E_{ref}
1	-1,62	-1,896	-2,271
2	-2,48	-2,346	-2,26
3	-2,697	-2,555	-2,266
Delta	1,077	0,658	0,011
Rang	1	2	3

TABLEAU IV.6 REPONSES POUR LES MOYENNES

Niveau	C	φ	E_{ref}
1	1,21	1,251	1,302
2	1,33	1,311	1,301
3	1,364	1,342	1,302
Delta	0,154	0,091	0,002
Rang	1	2	3

Le classement des paramètres de processus est obtenu par Minitab à l'aide des rapports signal / bruit et des moyennes pour différents niveaux de paramètres pour le facteur de sécurité a été donné dans les tableaux IV.5 et IV.6 respectivement.

Les dernières cases du bas indiquent le rang des entrées en fonction des résultats. Les rangs indiquent que le paramètre d'entrée le plus impactant est le cohésion (C), le deuxième en termes d'impact est l'angle de frottement (φ) et le troisième est E_{ref} , ce qui correspond fortement aux résultats ci-dessus.

TABLEAU IV.7 VALEURS OPTIMALES

Paramètres des variables (Unité)	Valeur optimale	Niveau
Cohésion (C)	5	1
Angle de frottement (φ)	30	1
E_{ref}	10000	2

A. Paramètres d'effet

Les lignes parallèles indiquent qu'il n'y a pas d'interaction entre les facteurs, les lignes de paramètres non parallèles jouent un rôle essentiel dans l'étude de l'interaction, cela suggère qu'il y a eu une interaction nominale. Si les lignes se croisent, cela indique qu'il y a eu une forte interaction entre les facteurs.




FIG IV.8 DIAGRAMME D'INTERACTION POUR LES RAPPORTS S / N

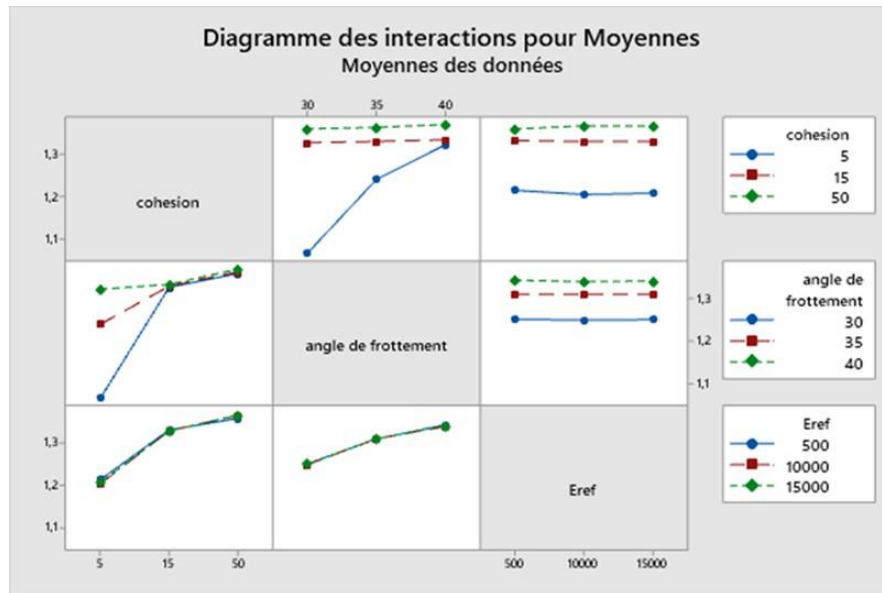


FIG IV.9 DIAGRAMME D'INTERACTION POUR LES MOYENNES 0

Le graphique d'interaction entre les paramètres de processus tels que la cohésion, l'angle de frottement et E_{ref} sont également représentés sur les figures IV.8 et IV.9. Nous pouvons voir qu'il existe une interaction substantielle entre la cohésion et l'angle de frottement, tandis qu'une interaction modérée entre la cohésion et E_{ref} et entre l'angle de frottement également.

Le graphique prédit clairement que la valeur de la réponse augmente progressivement à mesure que le niveau des paramètres la cohésion et l'angle de frottement augmente.

Comme le rapport signal sur bruit pris en compte est basé sur le plus petit pour le mieux, il est clair que le niveau optimisé de facteur de sécurité n'est réalisable que lorsque les paramètres la cohésion et l'angle de frottement sont réglés au niveau 1 tandis que E_{ref} est réglé au niveau 2.

IV. 3. 2 Validation des résultats d'analyse de Taguchi avec ANOVA

L'analyse de variance (ANOVA) est une technique statistique standard qui a été utilisée pour déterminer la fiabilité des résultats de l'expérience, dans notre cas Taguchi recherche les paramètres de processus les plus importants de la matrice orthogonale qui affectera les paramètres de sortie à l'aide du logiciel Minitab. Cette analyse a été effectuée avec niveau de confiance de 95% et un niveau de signification de 5% (Sayeed et al 2015), L'ANOVA calcule les quantités telles que les degrés de liberté (DF), les sommes des carrés (Seq SS), le rapport (F), la valeur (P) comme illustré dans le tableau IV.9.

Si la valeur P est inférieure à 0.05, le paramètre de processus est dit significatif et si la valeur P est supérieure à 0.05, les paramètres de processus sont considérés comme non significatifs.

TABLEAU IV.8 RESULTATS DE L'ANALYSE DE VARIANCE ANOVA

Source	DF	Seq SS	F	P
Cohesion (C)	2	0,118355	18,31	0.00
Angle de frottement (φ)	2	0,038425	5,94	0,009
E _{ref}	2	0,000011	0	0,998
Error	20	0,064656		
Total	26	0,221447		

Les résultats de l'ANOVA révèlent que le paramètre le plus efficace est la cohésion (C), comme le montre sa faible valeur P ($P < 0.05$) et sa valeur F élevée, suivies par l'angle de frottement (φ) avec une valeur P et valeur F considérablement faible avec E_{ref} est le seul facteur insignifiant, avec une valeur de 0.998 de P.

Les tracés résiduels sont utilisés pour examiner la qualité de l'ajustement du modèle. Minitab fournit les tracés résiduels suivants. L'interprétation de chaque graphique résiduel est donnée ci-dessous :




FIG IV.10 DROITE DE HENRY POUR LES RAPPORTS S / N

Le graphique de Droite de Henry révèle que presque tous les résidus suivent un modèle linéaire et qu'il ne semble pas y avoir de valeurs aberrantes, cela concorde bien avec les résultats.




FIG IV.11 VALEURS RESIDUELS PAR RAPPORT AUX VALEURS AJUSTEES

Les résidus par rapport aux valeurs ajustées (Figure IV.11) indiquent que les points apparaissent dispersés de manière aléatoire sur le tracé, qu'il existe une relation non linéaire et qu'aucune valeur aberrante n'est apparente, le résidu est principalement cumulatif autour de zéro, à l'exception de quelques points au-dessous.




FIG IV.12 RESIDUS PAR RAPPORT A L'ORDRE DES DONNEES

La figure IV.12 représente le schéma des résidus selon l'ordre. Les résidus sont disposés de manière aléatoire autour de la ligne médiane, puis disposés uniformément. Le graphique montre clairement que les résidus proches les uns des autres sont corrélés et donc non indépendants. Cela signifie que le modèle est valide.

IV. 3. 3 Application de la méthode des surfaces de réponses (RSM)

La méthodologie de surface de réponse (RSM) c'est un ensemble de techniques statistiques et mathématiques utiles pour le développement et l'optimisation des processus (Renata, D et Jacek, P 2018). La technique RSM la plus utilisée est la conception Box-Behnken (BBD), mentionné au chapitre II. Le processus a été réalisé selon l'outil de conception Box-Behnken de RSM à l'aide du logiciel Minitab 18 pour 3 facteurs sélectionnés (tableau IV. 2), afin de résoudre ce problème de minimisation du facteur de sécurité du talus, sur la base de simulations et des résultats obtenus en utilisant l'analyse par éléments finis avec Plaxis 2D. Dans cette étude, le plan Box-Behnken (BBD) a été réalisé avec un total de 15 expériences. Sur la base de la méthode Tagushi, nous aurions pu utiliser 27 expériences (L27), mais grâce au plan de Box-Behnken, ce nombre a été réduit à 15 expériences.

TABLEAU IV.9 PARAMETRES ET PLAGES POUR L'ANALYSE DU TALUS

Paramètres	Unités	Étiquettes	Faible (-1)	Haute (+1)
Cohésion	kN/m ²	(C)	05	50
Angle de frottement	Degré (°)	(φ)	30	40
E_{ref}	kN/m ²	E _{ref}	500	15000

TABLEAU IV.10 RESULTATS EXPERIMENTAUX SELON UN DESIGN BOX-BEHNKEN

Cas	Cohésion	Angle De frottement	E _{ref}	Variable de réponse expérimentale	Variable de réponse estimée
1	5	30	7750	1,063	1,106
2	50	30	7750	1,363	1,379
3	5	40	7750	1,318	1,301
4	50	40	7750	1,371	1,327
5	5	35	500	1,245	1,231
6	50	35	500	1,363	1,376
7	5	35	15000	1,238	1,224
8	50	35	15000	1,366	1,379
9	27,5	30	500	1,34	1,309
10	27,5	40	500	1,355	1,384
11	27,5	30	15000	1,34	1,310
12	27,5	40	15000	1,349	1,379
13	27,5	35	7750	1,345	1,345
14	27,5	35	7750	1,345	1,345
15	27,5	35	7750	1,345	1,345

IV. 3. 3. 1 Résultats et discussions

IV. 3. 3. 1. 1 Développement d'une équation de modèle de régression

Sur la base du plan expérimental donné dans le tableau IV.9, le RSM a proposé l'équations indiqué ci-dessous, c'est l'équation de régression développée. Le modèle mathématique représente l'effet quantitatif des facteurs d'entrée et de leurs interactions sur le facteur de sécurité.

Par conséquent, une bonne concordance entre les valeurs expérimentales et prédites confirme la validité du modèle (tableau IV.10).

Equation de régression en unités non codées

$$F_s = -0.17 + 0.02835 \text{ Cohesion} + 0.0551 \text{ Angle de frottement} - 0.000003 \text{ Eref} - \\ 0.000108 \text{ Cohesion} \times \text{Cohesion} - \\ 0.000465 \text{ Angle de frottement} \times \text{Angle de frottement} + 0,000000 \text{ Eref} \times \text{Eref} - \\ 0.000549 \text{ Cohesion} \times \text{Angle de frottement} + 0.000000 \text{ Cohesion} \times \text{Eref} - \\ 0.000000 \text{ Angle de frottement} \times \text{Eref} \quad (\text{IV. 3})$$

IV. 3. 3. 1. 2 Analyse de la variance

Les résultats sont analysés afin que les conditions puissent être optimisées pour donner des résultats très satisfaisants pour tous les paramètres de réponse.

Les résultats de calcul des facteurs de sécurité sont résumés dans le tableau IV.10.




FIG IV.13 EFFETS PRINCIPAUX

La pertinence du modèle de surface de réponse quadratique a été justifiée par l'ANOVA. Les deux paramètres : cohésion et angle de frottement ont un effet significatif sur le facteur de sécurité (Figure IV.13).




FIG IV.14 DIAGRAMME DE PARETO 0

Le diagramme de Pareto a été élaboré pour comparer l'ampleur relative des effets de divers facteurs sur la réponse, leur importance et leurs interactions. Les effets sont tracés par ordre décroissant de la valeur absolue des effets standardisés et trace une ligne de référence sur le graphique.

Comme la montre la figure IV.14, la barre de Pareto de l'effet d'entrée A (cohésion) et AB (interaction de cohésion et angle de frottement) se trouvent à droite de la ligne rouge verticale ; par conséquent, cette barre est statistiquement significative au niveau de signification de 5 % avec les termes du modèle actuel. Bien que AA, B soient en moyenne significatifs, alors que les autres facteurs C, CC, BB, BC, AC semblent insignifiants.


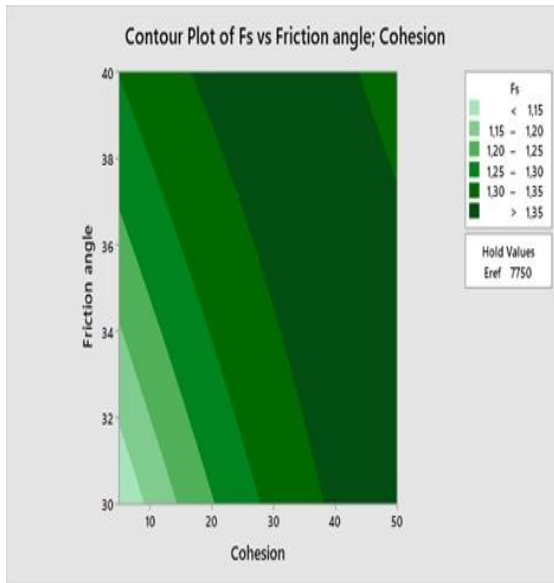


FIG IV.15 GRAPHIQUES NORMAUX POUR EFFETS STANDARDISES


Pour déterminer l'ampleur, la direction et l'importance des effets, nous pouvons utiliser le diagramme de probabilité normale des effets. Dans le graphique de la figure IV.15, l'effet principal des facteurs A (cohésion) et AB (cohésion et Angle de frottement) sur le facteur de sécurité est statistiquement significatif au niveau de 0,05. Ce point a une couleur et une forme distinctes (carré rouge) des points à effets insignifiants (cercle bleu). Le tracé normal des effets standardisés, a prouvé que les facteurs les plus importants sur le facteur de sécurité sont la cohésion et la cohésion-angle de frottement.

IV. 3. 3. 1. 3 Optimisation à l'aide de courbes de niveaux de réponse

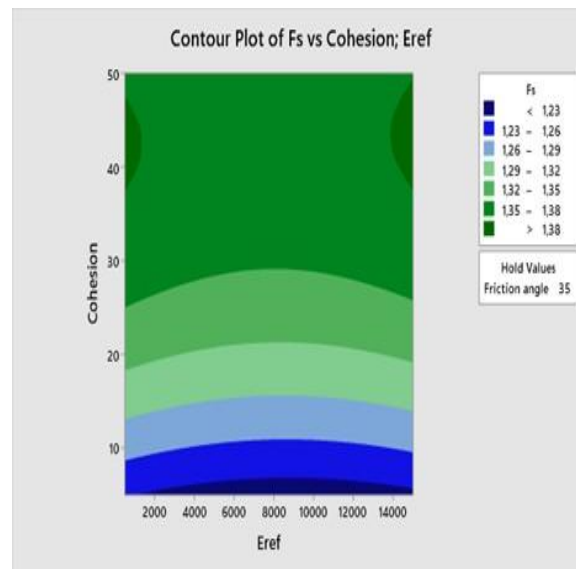
La relation entre les facteurs et les réponses est bien comprise lors de l'utilisation des courbes de niveau. Le traçage des contours fournit une vue 2D de la surface où les points ayant la même réponse sont connectés pour produire des lignes de contour de réponses constantes.



(a)



(b)



(c)

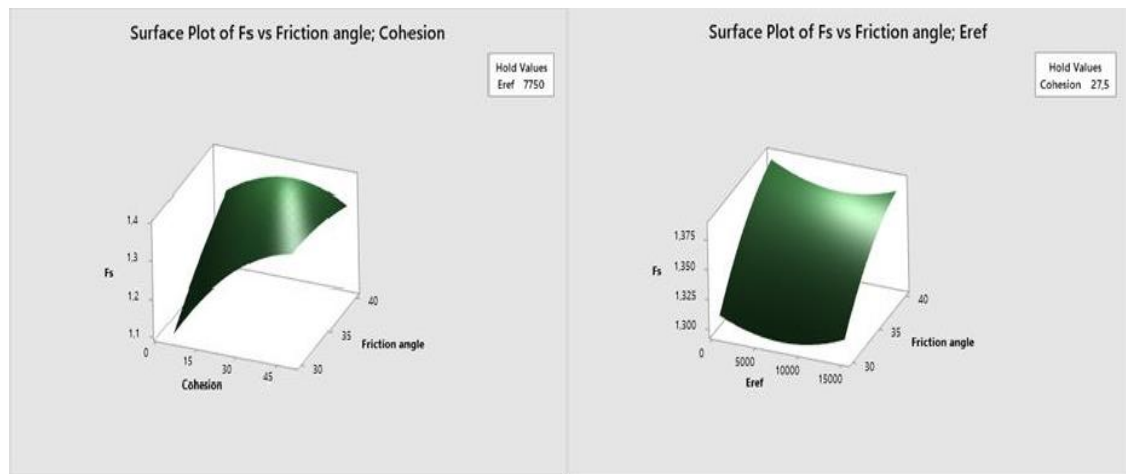
FIG IV.16 LIGNES DE CONTOUR

Sur les figures 16 a-b-c, les courbes de niveau montrent la réponse en fonction des variables : cohésion, Angle de frottement et E_{ref} . Les tracés sont très explicites quant à l'influence des paramètres sur le facteur de sécurité. On voit bien l'augmentation du

Chapitre IV Position du problème et Méthodologie de calcul


facteur de sécurité avec l'augmentation de la cohésion et de l'Angle de frottement. En revanche, E_{ref} a peu d'effet sur le facteur de sécurité (FigureIV.16c).

Les résultats sont également déduits de l'analyse d'un tracé de surface 3D. où la réponse est présentée dans une surface courbe continue, dans un espace 3D en fonction des paramètres d'intérêt. La variation des deux paramètres est incluse dans le test, tandis que le troisième paramètre reste inchangé.



(a)

(b)



(c)

FIG IV.17 COURBES DE SURFACE DE REPONSE F_s POUR UNE PENTE STABILISEE AVEC DES ECHANTILLONS A UN PARAMETRE CONSTANT DE : (A) 7 750 KPA D' E_{REF} , (B) 27,5 KPA DE COHESION ET (C) 35° D'ANGLE DE FROTTEMENT

Les tracés visualisent la réponse et les interactions entre les deux paramètres choisis. Par exemple, les surfaces de réponse sont présentées sur la figure IV.17. Notons les paramètres inchangés suivants : 7750 kPa de E_{ref} (Figure IV.17a), 27,5 kPa de cohésion (Figure IV.17b) et 35° d'angle de frottement (Figure IV.17c) respectivement. Le tracé de l'effet combiné cohésion-angle de frottement à 7750 kPa de E_{ref} est présenté sur la figure IV.17a et montre les effets interactifs de la cohésion et de l'angle de frottement sur le facteur de sécurité. Ces deux paramètres ont un effet positif sur l'amélioration de F_s tandis que E_{ref} reste inchangé, la pente gagne encore une certaine résistance. De plus, la cohésion est plus efficace que l'angle de frottement pour augmenter F_s . Lorsque l'angle de frottement est de 40° (soit la valeur maximale testée), l'efficacité de la cohésion sur l'amélioration de F_s est la plus significative.

La figure IV.17b montre les effets interactifs de l'angle de frottement et de E_{ref} sur F_s de la pente à une cohésion de 27,5 kPa. L'angle de frottement additif contribue à la résistance, tandis que l'augmentation de E_{ref} est marginale.

La figure IV.17c montre les effets interactifs de la cohésion et de E_{ref} sur F_s de la pente à un angle de frottement de 30° . De même, l'additif de cohésion contribue à la résistance, tandis que l'augmentation de E_{ref} est marginale.

De plus la figure IV.17b montre que l'angle de frottement améliore F_s , alors que le taux d'amélioration est moins important par rapport à celui obtenu en utilisant la cohésion (figure IV.17c). Cependant, F_s est faible jusqu'à ce que E_{ref} atteigne 7750 kPa après une augmentation marginale pour F_s .




FIG IV.18 OPTIMISATION

La figure IV.18 montre qu'une valeur intéressante recherchée à partir de la variable de réponse peut être prédite et obtenue à partir du modèle développé. Ainsi, une cohésion de 5 kN/m^2 , un angle de frottement de 30° et un E_{ref} de 8409 kN/m^2 , pour permettre une réponse variable (facteur de sécurité) de $1,1061$ avec une bonne désirabilité de $0,85990$.

IV. 3. 4 Application des Méthodes d'intelligence artificielles (l'Apprentissage Automatique)

Dans ce travail trois techniques d'intelligence artificielles ont été optées pour la prédiction du facteur de sécurité, Extreme gradient boosting, Random Forest et les réseaux de neurones artificiels. La base de données utilisée pour le développement des trois modèles est une base de données numérique. Cette dernière a été créé par l'utilisation du logiciel Plaxis 2D.

Pour obtenir une conception optimale, il faut tout d'abord choisir les facteurs et leurs niveaux de variation. Dans notre étude nous considérons quatre (4) facteurs, la cohésion(c), l'angle de frottement (φ), E_{ef} et le volume de remblai(V). Affectons trois (3) niveaux à chacun d'entre eux. Ces facteurs et leurs niveaux sont présentés dans le tableau IV.11.

TABLEAU IV.11 PARAMETRES ET NIVEAUX SELECTIONNES

N°	Paramètre	Unité	Niveau 1	Niveau 2	Niveau 2
1	C	kN/m ²	05	15	50
2	φ	Degré (°)	30	35	40
3	E _{ref}	kN/m ²	500	10000	15000
4	V	m ³	154,54	178,73	206,19

IV. 3. 4. 1 Résultats de la modélisation

Les facteurs de sécurité obtenus par l'utilisation du logiciel Plaxis 2D présentés au-dessous :

TABLEAU IV.12 FACTEURS DE SECURITE POUR LES DIFFERENTS PARAMETRES

Cohésion C (kPa)	Angle de frottement φ°	Module de Young E (kPa)	Volume V(m ³)	Facteur de sécurité Fs
5	30	500	154,54	1,013
5	35	500	154,54	1,152
5	40	500	154,54	1,312
5	30	500	178,73	1,064
5	35	500	178,73	1,243
5	40	500	178,73	1,331
5	30	500	206,19	1,141
5	35	500	206,19	1,313
5	40	500	206,19	1,335
5	30	10000	154,54	1,012
5	35	10000	154,54	1,153
5	40	10000	154,54	1,328
5	30	10000	178,73	1,328
5	35	10000	178,73	1,238
5	40	10000	178,73	1,337

Chapitre IV Position du problème et Méthodologie de calcul

5	30	10000	206,19	1,146
5	35	10000	206,19	1,333
5	40	10000	206,19	1,333
5	30	15000	154,54	1,01
5	35	15000	154,54	1,152
5	40	15000	154,54	1,325
5	30	15000	178,73	1,065
5	35	15000	178,73	1,24
5	40	15000	178,73	1,336
5	30	15000	206,19	1,146
5	35	15000	206,19	1,335
5	40	15000	206,19	1,34
15	30	500	154,54	1,384
15	35	500	154,54	1,388
15	40	500	154,54	1,387
15	30	500	178,73	1,35
15	35	500	178,73	1,337
15	40	500	178,73	1,337
15	30	500	206,19	1,35
15	35	500	206,19	1,353
15	40	500	206,19	1,361
15	30	10000	154,54	1,38
15	35	10000	154,54	1,383
15	40	10000	154,54	1,383
15	30	10000	178,73	1,345
15	35	10000	178,73	1,349
15	40	10000	178,73	1,353
15	30	10000	206,19	1,349
15	35	10000	206,19	1,353
15	40	10000	206,19	1,359

Chapitre IV Position du problème et Méthodologie de calcul

15	30	15000	154,54	1,378
15	35	15000	154,54	1,383
15	40	15000	154,54	1,387
15	30	15000	178,73	1,344
15	35	15000	178,73	1,35
15	40	15000	178,73	1,353
15	30	15000	206,19	1,347
15	35	15000	206,19	1,347
15	40	15000	206,19	1,359
50	30	500	154,54	1,409
50	35	500	154,54	1,414
50	40	500	154,54	1,419
50	30	500	178,73	1,381
50	35	500	178,73	1,383
50	40	500	178,73	1,386
50	30	500	206,19	1,386
50	35	500	206,19	1,394
50	40	500	206,19	1,395
50	30	10000	154,54	1,416
50	35	10000	154,54	1,42
50	40	10000	154,54	1,426
50	30	10000	178,73	1,382
50	35	10000	178,73	1,387
50	40	10000	178,73	1,393
50	30	10000	206,19	1,383
50	35	10000	206,19	1,389
50	40	10000	206,19	1,395
50	30	15000	154,54	1,416
50	35	15000	154,54	1,42
50	40	15000	154,54	1,425

50	30	15000	178,73	1,381
50	35	15000	178,73	1,386
50	40	15000	178,73	1,392
50	30	15000	206,19	1,382
50	35	15000	206,19	1,389
50	40	15000	206,19	1,399

IV. 3. 4. 2 Développement des modèles Extreme gradient boosting et Random Forest

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.metrics import mean_squared_error, mean_absolute_error
from sklearn.metrics import mean_absolute_percentage_error, r2_score
from sklearn.preprocessing import MinMaxScaler
from sklearn.model_selection import train_test_split, cross_val_score
from sklearn.ensemble import RandomForestRegressor, GradientBoostingRegressor
import xgboost as xgb
from xgboost import XGBRegressor
import seaborn as sns
```

FIG IV.19 BIBLIOTHEQUES UTILISEES DANS LES MODELE XGBOOST ET RF

IV. 3. 4. 2. 1 Description de l'ensemble de données

Une base de données complète est cruciale pour construire des modèles d'apprentissage automatique efficaces. Il comprend 81 valeurs réparties sur cinq paramètres clés, comme détaillé dans le tableau IV.13

TABLEAU IV.13 RESUME DE L'ENSEMBLE DE DONNEES

	C (kpa)	phi (°)	E (Mpa)	V(m3)	F_s
Count	81,000000	81,000000	81,000000	81,000000	81,000000
mean	23,333333	35,000000	8500,000000	179,820000	1,327877
std	19,413269	4,107919	6051,342826	21,231572	0,102041
min	5,000000	30,000000	500,000000	154,540000	1,010000
25%	5,000000	30,000000	500,000000	154,540000	1,333000
50%	15,000000	35,000000	10000,000000	178,730000	1,353000
75%	50,000000	40,000000	15000,000000	206,190000	1,387000
max	50,000000	40,000000	15000,000000	206,190000	1,426000

IV .3.4.2.2 Normalisation

La normalisation est une étape cruciale dans le prétraitement des données pour l'apprentissage automatique. Elle consiste à mettre les variables numériques à une échelle commune, ce qui est particulièrement important lorsque les données présentent des écarts d'ordre de grandeur. En normalisant les données, on améliore significativement la convergence des algorithmes d'apprentissage, notamment ceux basés sur la descente de gradient. De plus, la normalisation contribue à une meilleure interprétation des coefficients du modèle et facilite la comparaison entre les différentes variables.

Le tableau ci-dessous montre les cinq premières lignes de la base de données après normalisation.

TABLEAU IV.14 LES DONNEES APRES NORMALISATION

C (kpa)	phi (°)	E (Mpa)	V(m3)	F _s
1,0	0,5	1,0	0,468345	0,903846
1,0	1,0	1,0	1,000000	0,935096
1,0	0,0	1,0	0,468345	0,891827
1,0	0,5	1,0	1,000000	0,911058
1,0	1,0	1,0	0,000000	0,997596

Comprendre les relations entre les variables est essentiel avant la construction d'un modèle. Les figures IV.20 et IV.21 offrent un aperçu visuel de ces relations. La figure IV.20 est une carte thermique de matrice de corrélation, qui permet de visualiser les coefficients de corrélation entre les variables, révélant des modèles d'association. Selon la Heatmap, la cohésion et l'angle de frottement interne sont les paramètres les plus influents sur le facteur de sécurité de la pente.





FIG IV.20 MATRICE DE CORRELATION DE CINQ VARIABLES D'ENTREE ET D'UNE VARIABLE DE SORTIE 0

La figure IV.21 est un **graphique en matrice de corrélation** (ou pair plot). Cet outil de visualisation offre une vue d'ensemble des distributions individuelles de chaque variable ainsi que de leurs relations bilatérales. Les **nuages de points** qui composent cette matrice permettent d'identifier visuellement des tendances linéaires, des corrélations non linéaires, et des valeurs aberrantes, facilitant ainsi l'exploration de potentielles interactions entre les variables.



FIGIV.21 PAIR PLOT DES DIFFERENTS PARAMETRES DE LA BASE DE DONNEES

IV. 3. 4. 2. 3 Division des données stratégiques

La base de données a été divisée en deux ensembles distincts pour garantir un développement et des tests de modèles robustes. Pour cela, un ensemble d'entraînement : de 75 % des données (60 échantillons) est utilisé pour entraîner le modèle sur les modèles et les relations au sein des données. L'ensemble de tests constitue les 25 % restants des échantillons et est utilisé pour évaluer les performances du modèle sur des données invisibles et évaluer ses capacités de généralisation.

IV. 3. 4. 3 la Méthode XGBoost (Extreme Gradient Boosting)

IV. 3. 4. 3. 1 Validation croisée K-Fold

La validation croisée est une technique robuste d'évaluation des performances d'un modèle d'apprentissage automatique. En divisant de manière répétée les données en ensembles d'entraînement et de test, elle permet d'obtenir une estimation plus précise et moins biaisée des performances généralisation du modèle, comparativement à une simple partition en un ensemble d'entraînement et un ensemble de test.

Cet ensemble de données est divisé en K plis (sections) de taille égale. Pour chaque pli, le modèle est entraîné sur les plis K-1. Les performances du modèle sont évaluées sur le pli restant (données invisibles). Ce processus est répété K fois, garantissant que chaque point de données est utilisé à la fois pour la formation et l'évaluation. La validation croisée K-Fold atténue le risque de surajustement en évaluant les performances du modèle sur plusieurs ensembles de données invisibles et révèle les biais et sensibilités potentiels du modèle à différents sous-ensembles de données. Dans notre étude, un K est égal à 5.

IV. 3. 4. 3. 2 Les indices de performance

Afin d'évaluer la performance des modèles développés, nous avons retenu deux critères couramment utilisés : la racine carrée de l'erreur quadratique moyenne (RMSE), permet

d'obtenir une mesure de l'écart moyen entre les prédictions et les véritables valeurs, qui plus facilement interprétable en termes d'échelle la variable d'origine, tout en ayant l'avantage de limiter l'impact des valeurs aberrantes et le coefficient de détermination (R^2). Ces métriques nous permettent d'appréhender respectivement l'écart moyen entre les valeurs prédites et les valeurs observées, ainsi que la proportion de la variance des données expliquée par le modèle. Les formules mathématiques spécifiques de ces indices sont données dans les équations (IV.4) (IV.5) garantissant transparence et reproductibilité.

Erreur quadratique moyenne (RMSE)

$$RMSE = \sqrt{\frac{\sum_{i=1}^m (y_{actual} - y_{prediced})^2}{m}} \quad (IV.4)$$

m : nombre des échantillons de la base de données

Le coefficient de détermination (R^2)


$$R^2 = 1 - \frac{SS_E}{SS_T} = 1 - \frac{\sum_{i=1}^n (y_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \hat{y})^2} \quad (IV.5)$$

\bar{y} : est la valeur prédire

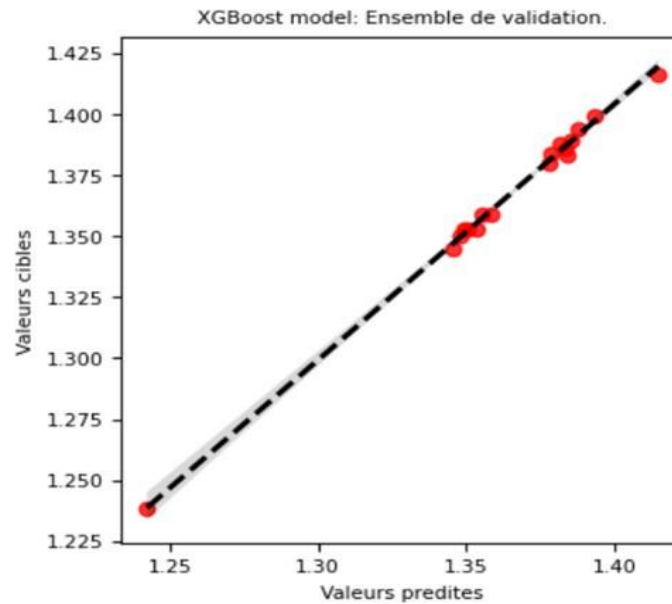
\hat{y} : est la valeur de de réponses

IV. 3. 4. 3. 3 Résultats et discussions

Pour évaluer visuellement la précision du modèle, les corrélations entre les valeurs prédites et cibles ont été représentées sous forme graphique.



FIGIV.22 LES VALEURS CIBLES DU FACTEUR DE SECURITE PAR RAPPORT AUX VALEURS PREDITES DE L'ENTRAINEMENT DEFINIES A L'AIDE DU MODELE PROPOSE (XGBOOST)



FIGIV.23 LES VALEURS REELLES DU FACTEUR DE SECURITE PAR RAPPORT AUX VALEURS PREDITES DES TESTS EFFECTUES A L'AIDE DU MODELE PROPOSE (XGBOOST) 0

Les chiffres de corrélation (22 ,23) et les valeurs des critères de performance (RMSE=1.28x10⁻⁵, R2=0.990) démontrent collectivement l'efficacité du modèle dans la prévision des facteurs de sécurité de stabilité des pentes.

TABLEAU IV.15 LES VALEURS DES MESURES DE PERFORMANCE (XGBOOST)

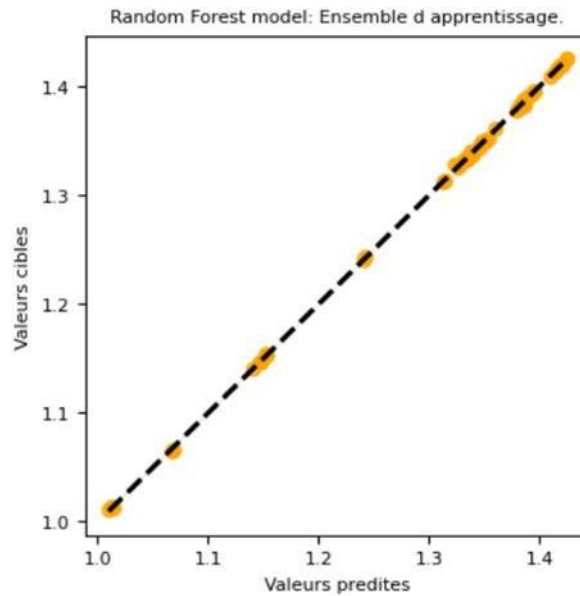
Set	RMSE	R2
Training Set	1,59x10 ⁻⁶	0,999
Testing Set	1,28x10 ⁻⁵	0,990

IV. 3. 4. 4 la Méthode du Random Forest (RF)


La méthodologie d'analyse initialement conçue pour l'algorithme XGBoost a été adaptée et appliquée à l'algorithme Random Forest. Les résultats obtenus ont été synthétisés dans les figures et le tableau indiqué ci-dessous, présentant notamment les valeurs des métriques de performance clés.

TABLEAU IV.16 LES VALEURS DES MESURES DE PERFORMANCE (RF)

Set	RMSE	R2
Training Set	1,59x10 ⁻⁶	0,999
Testing Set	1,28x10 ⁻⁵	0,990



FIGIV.24 LES VALEURS CIBLES DU FACTEUR DE SECURITE PAR RAPPORT AUX VALEURS PREDITES DE L'ENTRAINEMENT DEFINIES A L'AIDE DU MODELE PROPOSE (RF)



FIGIV.25 LES VALEURS REELLES DU FACTEUR DE SECURITE PAR RAPPORT AUX VALEURS PREDITES DES TESTS EFFECTUES A L'AIDE DU MODELE PROPOSE (RF)

La similitude des résultats entre XGBoost et Random Forest est probablement due à leur fondement commun en tant que techniques appartenant aux ensemble multiple modèle d'apprentissage automatique. Les deux modèles utilisent des arbres de décision comme apprenants de base, combinant plusieurs arbres pour faire des prédictions plus précises et plus robustes.

Bien que les mécanismes sous-jacents de XGBoost et de Random Forest diffèrent (boosting vs. Bagging), leurs points forts en matière de gestion des relations complexes, de réduction du surajustement et d'amélioration de la généralisation contribuent probablement à leurs performances comparables dans de nombreux scénarios.

IV. 3. 4. 5 Réseau de neurones artificiels (RNA)

Dans cette section, nous avons utilisé la bibliothèque Keras, basé sur Python, pour développer des réseaux de neurones afin de prédire le facteur de sécurité. Ce choix s'est porté sur Keras en raison de sa simplicité d'utilisation et de sa flexibilité. Les bibliothèques essentielles employées dans cette étude sont présentées dans le code ci-dessous.

```
Entrée [34]: 1 import numpy as np
2 import pandas as pd
3 import seaborn as sns
4 import matplotlib.pyplot as plt
5 from sklearn.model_selection import train_test_split
6 from sklearn.preprocessing import StandardScaler
7 import tensorflow as tf
8 from tensorflow.keras.models import Sequential
9 from tensorflow.keras.layers import Dense
10 from sklearn.metrics import r2_score
11 from sklearn.metrics import mean_squared_error, accuracy_score
12 from sklearn.metrics import mean_absolute_error
```

FIG IV.26 BIBLIOTHEQUES UTILISEES DANS LE MODELE RNA

La figure IV.27 illustre l'architecture du réseau de neurones utilisé dans notre travail. Le réseau est composé de deux couches cachées est une couche de sortie contenant une seule sortie (F_S).

Model: "sequential_5"

Layer (type)	Output Shape	Param #
dense_14 (Dense)	(None, 64)	320
dense_15 (Dense)	(None, 32)	2,080
dense_16 (Dense)	(None, 1)	33

Total params: 7,301 (28.52 KB)

Trainable params: 2,433 (9.50 KB)

Non-trainable params: 0 (0.00 B)

Optimizer params: 4,868 (19.02 KB)

FIG IV.27 PRESENTATION DU MODELE RNA (MODELE RECAPITULATIF) 0


IV. 3. 4. 4. 1 Résultats et discussions

Les résultats obtenus démontrent la capacité du modèle à prédire avec précision le facteur de sécurité. Les faibles valeurs de RMSE et de MAE indiquent un écart réduit entre les valeurs prédites et les valeurs réelles.


TABLEAU IV.17 LES VALEURS DES MESURES DE PERFORMANCE (RNA)

Set	RMSE	R2
Training Set	0,043	0,95
Testing Set	0,147	0,97

Afin de montre l'efficacité du model, des figures de corrélations entre valeurs réelles et prédites ont été tracées Figures (IV.28, IV.29).



FIGIV.28 LES VALEURS CIBLES DU FACTEUR DE SECURITE PAR RAPPORT AUX VALEURS PREDITES DE L'ENTRAINEMENT DEFINIES A L'AIDE DU MODELE PROPOSE (RNA)



FIGIV.29 LES VALEURS REELLES DU FACTEUR DE SECURITE PAR RAPPORT AUX VALEURS PREDITES DES TESTS EFFECTUES A L'AIDE DU MODELE PROPOSE (RNA)

D'après les résultats des figures montrent, un alignement des points autour de la droite (figures IV.23, IV.24, IV.25, IV.26) et d'autres montrent que les points sont relativement proches de la droite de régression (figures IV.28, IV.29) ce qui suggère, une bonne adéquation du modèle aux données et un témoin d'une bonne qualité de prédiction du modèle pour le FS.

IV. 4 Conclusion

Dans ce travail nous avons appliqué une méthodologie pour optimiser des paramètres d'un terrain en pente (talus) en utilisant deux techniques des techniques d'optimisation et des techniques d'intelligence artificielles.

Pour les techniques d'optimisation en appliquant la méthode DOE tel que (la méthode Taguchi et la surface de réponse RSM).

L'optimisation par la méthode Taguchi mono-objectif a été réalisée en tenant compte du rapport signal sur bruit (S/N). Ce rapport nous a permis d'identifier la combinaison optimale des paramètres du sol : cohésion, angle de frottement et module E_{ref} tout en minimisant le facteur de sécurité qui a été composé d'une cohésion de 5 kN/m², d'un angle de frottement de 30° et d'un module E_{ref} de 10000 kN/m².

Pour la méthode RSM la combinaison optimale des paramètres c'est la même que la méthode de Taguchi à l'exception de E_{ref} avec une valeur de 8409 kN/m² est obtenue comme valeur optimale. La méthode RSM (Conception Box–Behnken) est une méthode statistique très utile qui a permis de réduire le nombre d'expérimentations. L'un des avantages de la méthode réside dans l'analyse statistique qui permet d'envisager le problème d'optimisation sous plusieurs facettes (notamment en termes de probabilités et de désirabilité au regard des paramètres considérés). Les interactions mutuelles entre les variables indépendantes sont décrites avec des équations quadratiques qui prédisent la réponse dans les conditions appliquées.

Nous avons également observé que le module Eref du sol n'affecte pas la stabilité de la pente car la résistance au cisaillement (stabilité) du sol dépend totalement des paramètres de cisaillement tels que la cohésion et l'angle de frottement interne.

Pour clarifier et étayer les résultats de la recherche, nous avons utilisé les techniques d'intelligence artificielles représenté par, Extreme gradient boosting, Random Forest et les réseaux de neurones artificiels (RNA) composé de deux couches cachées est une couche de sortie contenant une seule sortie (F_s) en appliquant le langage python, qui est besoin d'un module important appelé keras. Les résultats obtenus montrent que le model a bien prédit le facteur de sécurité. Cela peut être constaté par les valeurs faibles de RMSE et R^2 .

La procédure suivie est celle des méthodes de XGBoost et Random Forest. Où une base de données a été divisée en deux ensembles. Un pour l'apprentissage et le 2ème pour la validation des modèles. Dans cette thèse, les proportions de 75% pour l'apprentissage et 25% pour la validation ont été considérées.

Le cadre XGBoost développer un modèle précis pour prédire le déplacement de la pente. La procédure de validation croisée (CV) K-fold est utilisée. Cette technique est efficace pour régler les hyperparamètres du modèle XGBoost.

Les modèles développés des méthodes de XGBoost et Random Forest et les réseaux de neurones artificiels possèdent d'excellentes capacités de généralisation et ne nécessitent pas de formes fonctionnelles prédéfinies. Il a atteint une précision remarquable dans la prévision du déplacement de la pente, comme en témoignent les faibles valeurs mesures de performance RMSE et les valeurs élevées de mesures de performance R^2 . Cela signifie un degré élevé de cohérence et de fiabilité dans ses prévisions.

Conclusions Générales et Perspectives

Cette étude avait pour objectif d'évaluer la stabilité d'un talus situé sur la RN12 au PK 119+000 dans la wilaya de Bejaïa, zone connue pour ses mouvements de terrain. En s'appuyant sur des méthodes d'optimisation statistiques (Taguchi, ANOVA, RSM) et des techniques d'apprentissage automatique (XGBoost, Random Forest, réseaux de neurones), nous avons cherché à développer une approche prédictive robuste pour ce type de structure.

Plus spécifiquement, nous avons mis en œuvre un modèle numérique permettant d'identifier la combinaison optimale de paramètres géotechniques (cohésion C , angle de frottement ϕ , module d'Young de référence E_{ref}) ainsi que le volume de remblai (V) qui minimise le facteur de sécurité F_s . Ce paramètre, indicateur direct de la stabilité du talus, a été optimisé à l'aide de différentes méthodes numériques.

La méthode de Taguchi s'est révélée particulièrement efficace pour identifier rapidement et précisément la combinaison optimale des paramètres influençant la stabilité du talus. En effet, cette approche a permis de hiérarchiser clairement les facteurs, mettant en évidence la cohésion comme le paramètre le plus déterminant, suivi de l'angle de frottement. Ces résultats sont corroborés par l'analyse de variance (ANOVA), qui confirme la haute significativité de la cohésion et de l'angle de frottement sur la réponse étudiée. En revanche, le module d'Young de référence (E_{ref}) s'avère avoir un impact négligeable sur la stabilité du talus dans le cadre de cette étude.

Par ailleurs, l'utilisation du plan d'expériences de Box-Behnken, une méthode de la surface de réponse (RSM), a permis d'optimiser les paramètres du talus en s'appuyant sur les résultats de l'ANOVA. Les représentations graphiques obtenues (courbes de contour, surfaces 3D) offrent une visualisation intuitive des interactions entre les

Conclusions Générales et Perspectives

différents facteurs et permettent de déterminer les conditions optimales pour assurer la stabilité du talus.

La méthode de Taguchi présente l'avantage de permettre l'optimisation simultanée de nombreux facteurs, tout en requérant un nombre réduit d'expériences. Elle a ainsi permis d'identifier rapidement la combinaison optimale des paramètres influençant la stabilité du talus.

Par ailleurs, l'étude a exploré l'utilisation de techniques d'apprentissage automatique telles que XGBoost, Random Forest et les réseaux de neurones artificiels. Ces modèles, notamment XGBoost et Random Forest, ont démontré d'excellentes capacités de généralisation grâce à leur structure ensembliste, permettant ainsi d'établir des prédictions robustes sans nécessiter de hypothèses préalables sur la forme de la relation entre les variables. Les réseaux de neurones, quant à eux, ont été configurés avec deux couches cachées pour modéliser les complexités potentielles des données.

Les résultats obtenus montrent que les trois modèles d'apprentissage automatique offrent des performances élevées dans la prévision de la stabilité des talus, comme en témoignent les faibles valeurs de RMSE et les élevées valeurs de R^2 . Ces résultats suggèrent que les techniques d'apprentissage automatique constituent un outil prometteur pour l'évaluation de la stabilité des talus, complétant ainsi les approches traditionnelles.

Les travaux futurs pourraient s'orienter vers :

- **Une modélisation 3D plus réaliste** du talus, intégrant des analyses statiques et dynamiques pour mieux appréhender les mécanismes d'instabilité.
- **Le développement de méthodes d'optimisation multi-objectifs** afin de prendre en compte simultanément différents critères de performance (coût, impact environnemental, etc.).

Conclusions Générales et Perspectives

- **L'exploration d'autres algorithmes d'apprentissage automatique** tels que les réseaux de neurones convolutifs ou les transformateurs, pour améliorer encore les performances de prédiction.
- **L'intégration d'incertitudes** dans les modèles afin de mieux quantifier les risques associés aux prédictions.

En conclusion, cette étude a mis en évidence l'intérêt de combiner des méthodes statistiques et d'apprentissage automatique pour l'optimisation de la stabilité des talus. Les résultats obtenus constituent une avancée significative dans ce domaine et ouvrent de nouvelles perspectives pour la gestion des risques liés aux mouvements de terrain.

Références

- Abderrahim., Z et Hachemi., A. (2019). Optimisation des paramètres géotechnique des sols par la méthode des surfaces de réponse. Mémoire de Master. Université 08 Mai 1945 Guelma.
- Aiboud, L., Laskri, S. (2020). Appréciation de la qualité des leads dans le marketing numérique à l'aide de l'apprentissage profond. Université Mouloud Mammeri de Tizi-Ouzou. Faculté de : Génie électrique et d'informatique.
- Alavi, A.H., Heshmati, A.A.R., Gandomi, A.H., and al. (2008). Utilisation of Computational Intelligence Techniques for Stabilised Soil. In “Engineering Computational Technology” (M. Papadrakakis, B.H.V. Topping Eds.), pp 175, Civil-Comp Press, Edinburgh, UK.
- Alavi, A.H., Gandomi, A.H., Gandomi, M., and Sadat Hosseini, S.S. (2009a). Prediction of Maximum Dry Density and Optimum Moisture Content of Stabilized Soil Using RBF Neural Networks. *The IES J. Part A: Civil Struct. Eng.* 2(2), 98–106.
- Alavi, A.H., Gandomi, A.H., Mollahasani, A., Heshmati, A.A.R. and Rashed, A. (2010a). Modeling of maximum dry density and optimum moisture content of stabilized soil using artificial neural networks. *J. Plant Nutr. Soil Sci.* 173, P368–379.
- Alavi, A.H., Gandomi A.H., Mousavi, M., and Mollahasani, A. (2010b). High-precision modeling of uplift capacity of suction caissons using a hybrid computational method. *Geomech. Eng.* 2(4), 253–280 ,3.
- Alavi, A.H., and Gandomi, A.H. (2011b). Prediction of principal ground-motion parameters using a hybrid method coupling artificial neural networks and simulated annealing. *Comput. Struct.* 89(23–24), 2176– 2194, 2.
- Alexis, J. (1995). *Pratique industrielle de la méthode Taguchi : les plans d'expériences.* Association française de normalisation.
- Anderson, M. and Braak, C.T. (2003). Permutation tests for multi-factorial analysis of variance. *Journal of statistical computation and simulation*, 73(2) ,85–113.
- Arai, K., and Tagyo, K. (1985). Determination of noncircular slip surfaces giving the minimum factor of safety in slope stability analysis. *Soils and found.* 21, 43–51.

Références

Armaghani, D.J and al. (2019). Hybrid ANN-based techniques in predicting cohesion of sandy-soil combined with fiber. *Geomechanics and Engineerin.* DOI: <https://doi.org/10.12989/gae.2020.20.3.191>.

Bagaber,S.A and Yusoff ,A.R .(2018). Multi-responses optimization in dry turning of a stainless steel as a key factor in minimum energy. *The International Journal of Advanced Manufacturing Technology* 96, P 1109–1122. <https://doi.org/10.1007/s00170-018-1668-8>.

Baillet, F. (2017). *Manuel d'utilisation des plans d'expériences. Une méthodologie robuste pour modéliser empiriquement un phénomène.* Ellipses Marketing.

Baker, R., and Garber, M. (1978). Theoretical analysis of the stability of slopes. *Geotechnique*, London. 28(4), P395-411.

Baker, R. (1980). Determination of the critical slip surface in slope stability computations. *International Journal for Numerical & Analytical Methods in Geomechanics* .4 (4), P333–359.

Baykasoglu, A., Cevik, A., Ozbakır, L., and Kulluk, S. (2009). Generating prediction rules for liquefaction through data mining. *Expert Systems with Applications*. 36, P12491–12499.

Benahmed, N. (2002). *Optimisation de réseaux de neurones pour la reconnaissance de chiffres manuscrits isolés : sélection et pondération des primitives par algorithmes génétiques*, Mémoire de Maîtrise. Ecole de Technologie Supérieure Montréal.

Benayoun, F., Boumezerane, D., & Rahab, B.S. (2021). Techniques for optimizing parameters of soil nailed vertical cut. *Selected Scientific Papers - Journal of Civil Engineering*, 16(1), P131-145.

Benayoun, F., Boumezerane, D., Bekkouche, S.R. et al. (2021). Optimization of geometric parameters of soil nailing using response surface methodology. *Arab J Geosci* 14, 1965. <https://doi.org/10.1007/s12517-021-08280-z>.

Benayoun, F. (2021). *Optimization in soil improvement and reinforcement problems.* these, Faculté de Technologie. Université 20 Août 1955-Skikda.

Références

- Benbouras., M.A. (2018). L'utilisation des SIG sur les données d'infrastructure et de fondations : Application dans la zone d'Alger. Thèse. Université Abbes Laghrour Khenchela.
- Bezerra, M.A., Santelli, R.A and al. (2008). Response surface methodology (RSM) as a tool for optimization in analytical chemistry. *Talanta. science direct.* 76(5),965-977.
- Bhandary,R.P., Krishnamoorthy,A., & Rao, A.U. (2018). Stability analysis of slopes using finite element method and genetic algorithm. *Journal of Geotechnical and Geological Engineering, Research.* 37, 1877–1889. <https://doi.org/10.1007/s10706-018-0730-5>.
- Bharti, J.P., Mishra, P., moorthy, U., and al. (2021). Slope Stability Analysis Using Rf, Gbm, Cart, Bt and Xgboost. *Geotech Geol Eng* .39, P3741–3752. <https://doi.org/10.1007/s10706-021-01721-2>.
- Bin Mohamad, A., Siddiquee, A.S., Abdul Quadir, G., Khan, Z.A.and Saini, V.K. (2012). Optimization of EDM process parameters using Taguchi method, *International Conference on Application and Design in Mechanical Engineering (ICADME)*, Penang, Malaysia.
- Bishop, A.W. (1955). The use of the slip circle in the stability analysis of slopes. *Géotechnique* .5, P7–17.
- Blondeau, F. (1976). Les méthodes d'analyse de stabilité des talus, *Lab. des ponts et chaussées.* 1(56).
- Bourougaa. N., and Seridi. M. (2020). Application des réseaux de neurone pour la classification des Données. *Mémoire de Master. Université 8 Mai 1945 Guelma.*
- Breiman,L .(2001). Using Iterated Bagging to Debias Regressions. *springer link.* 45, P261– 277.
- Breiman, L. (2001). Random forests. *Machine learning.* 45(1), P5-32.
- Cornuéjols, A., Miclet, L., and Kodratoff, Y. (2002). *Apprentissage Artificiel, Concepts et algorithmes*, ISBN 2-212-11020-0.

Références

- Celestino, T. B., and Duncan, J. M. (1981) Simplified search for noncircular slip surface. Proc., 10th Int. Conl. on Soil Mech. and Found. Engrg., A. A. Balkema, Rotterdam, The Netherlands. 3, P391-394.
- Chen, W. F. (1975). Limit Analysis and Soil Plasticity, Developments in geotechnical Engineering. Elsevier Scientific Publishing Company, New York. N°7.
- Chen, Z.Y., and Shao, C.M. (1988). Evaluation of minimum factor of safety in slope stability analysis. Can. Geotech. J. 25(4), P735- 748.
- Chen, T., and Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, P785-794, ACM.
- Cheng, Y.M., Li, L. and al. (2007). Performance studies on six heuristic global optimization methods in the location of critical slip surface. computers and geotechnical. ScienceDirect. 34(6). P 462-484.
- Cheng, M.Y., and Hoang, N.D. (2015). Typhoon-induced slope collapse assessment using a novel bee colony optimized support vector classifier. Springer link. Vol 78, P 1961–1978.
- Dede, T., Kripka, M., Togan, V., Yepes, V. and Rao, R.V. (2019). Usage of Optimization Techniques in Civil Engineering During the Last Two Decades. Current Trends in Civil & Structural Engineering. 1(1), P.1-17.
- Dhruva Karir., Arunava Ray., Ashutosh Kumar Bharati and al. (2022). Stability prediction of a natural and man-made slope using various machine learning algorithms. Transportation Geotechnics (science direct). 34.P 100745.
- Dietterich, T. G. (2000). Ensemble methods in machine learning. In International Workshop on Multiple Classifier Systems. Springer, Berlin, Heidelberg, P 1-15
- Djelailia, D. (2024). Application web pour calculer la capacité portante du sol à l'aide de la technique XGboost. Mémoire de Master. Université Souk-Ahras.
- Dounane., N. (2021). Application des plans d'expérience pour l'étude des sols gonflants. Thèse. Université Djillali Liabés Sidi Bel Abbès.

Références

- Dreyfus, G. (2004). Réseaux de neurones : Méthodologie et application, édition Eyrolles.
- Duncan, J.M. (1996). State of the art: limit equilibrium and finite element analysis of slopes. *J Geotech Eng* .122(7), P 577–596.
- Emrehan Kutlug Sahin. (2020). Assessing the predictive capability of ensemble tree methods for landslide susceptibility mapping using XGBoost, gradient boosting machine, and random forest. *springer link*. 2, N°1308.
- Erzin, Y., and Cetin, T. (2013). The prediction of the critical factor of safety of homogeneous finite slopes using neural networks and multiple regressions. *Computers & Geosciences. Sciences direct*. 51.P 305-313.
- Fawaz, A., Farah, E., and Hagechade, F. (2014). Slope stability analysis using numerical modeling, *American Journal of Civil Engineering*. 2, P.60-67.
- Fellenius, W. (1936). Calculation of stability of earth dams. *Transactions of Second Congress on Large Dams*. 4, 445-459.
- Ferentinou, M.D., and Sakellariou, M.G. (2007). Computational intelligence tools for the prediction of slope performance. *Comput Geotech* .34(5),362–384.
- Fotis, S., Besseris, G., and Alafodimos, K. (2008). Application of Taguchi's Experimental Design methodology for Product optimization in Food Engineering Mixtures. *Proceedings 3rd International Scientific Conference (ERA-3), Aegina, Greece*.
- Fredlund, D.G and Krahn, J. (1977). Comparison of slope stability methods of analysis. *Canadian Geotechnical Journal* .14 (3), 429– 439.
- Freund, Y., and Schapire, R.E. (1996). Experiments with a new boosting algorithm. *icml 96*:148–156. <http://www.research.att.com/orgs/ssr/people/yoav,schapire/>.
- Friedman, J.H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of statistics*.29(5),221–246.
- Friedman, J., Hastie, T., and Tibshirani, R. (2001). *The elements of statistical learning*. Springer series in statistics New York, 1, N°10.
- Friedman, J.H. (2002). Stochastic gradient boosting. *Computational Statistics & Data Analysis*. 38(4),367–378. doi:10.1016/S0167-9473(01)00065-2.

Références

- Goh, A.T.C. (1999). Genetic algorithm search for critical slip surface in multiple-wedge stability analysis. *Canadian Geotechnical Journal*. <https://doi.org/10.1139/t98-110>.
- Gong, W., Wang, L., Juang, C. H., Zhang, J., and Huang, H. (2014). Robust geotechnical design of shield-driven tunnels. *Computers and Geotechnics*, 56, P191–201.
- Goupy, J., Creighton, L. (2001). *Introduction aux plans d'expériences*. Dunod, Paris.
- Güllü, H., and Fedakar, H.İ. (2017). Response surface methodology for optimization of stabilizer dosage rates of marginal sand stabilized with Sludge Ash and fiber based on UCS performances. *KSCE J Civ Eng*. 21(5), P1717–1727.
- Himanshu, N., and Burman, A. (2019). Determination of Critical Failure Surface of Slopes Using Particle Swarm Optimization Technique Considering Seepage and Seismic Loading. *springer link*. 37, pp 1261–1281.
- Hornik, k., Stinchcombe, M., and White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2, (5), P359-366.
- https://fr.wikipedia.org/wiki/Neurone_formel (visité au 10/04/2020).
- <http://www.statsoft.fr/concepts-statistiques/reseaux-de-neuronesautomatisees/reseaux-de-neurones-automatisees.htm#fonctions> (visité au 18/08/2020).
- Javadi, A.A., Rezania, M., and Nezhad, M.M. (2006). Evaluation of liquefaction induced lateral displacements using genetic programming. *Comput. Geotech.* 33, 4–5, 222–233.
- Jiju, A. (2006). Taguchi or Classical design of experiments: a perspective from a practitioner. *Sensor Review*. 26(3), P227-230.
- Kalatehjari, K., Ali, N., Hajihassani, M., and Kholghi Fard, M. (2012). The Application of Particle Swarm Optimization in Slope Stability Analysis of Homogeneous Soil Slopes. *international Review on Modelling and Simulations*. 5, N. 1. ISSN P1974-9821.
- Kalatehjari, R., Arefnia, A., and al. (2015). Determination of three-dimensional shape of failure in soil slopes. *Canadian Geotechnical Journal*. <https://doi.org/10.1139/cgj-2014-0326>.
- Kang, F., Xu, Q., and al. (2016). Slope reliability analysis using surrogate models via new support vector machines with swarm intelligence. *Applied Mathematical Modelling*. 40, Issues 11–12, P 6105-6120.

Références

- Kang, F., Xu, B., and al. (2017). Slope stability evaluation using Gaussian processes with various covariance functions. *Applied Soft Computing*. science direct. 60, P 387-396.
- Karazhiyan et al. (2011). Extraction optimization of a hydrocolloid extract from cress seed (*Lepidium sativum*) using response surface methodology. *Food Hydrocolloids*. science direct, 25 (5), P915-920.
- Karir, D., Ray, A., and al. (2022). Stability prediction of a natural and man-made slope using various machine learning algorithms. *Transportation Geotechnics*; Volume 34. 100745. <https://doi.org/10.1016/j.trgeo.2022.100745>.
- Karna, S.K., and Sahai, R. (2012). An overview on Taguchi method, *International journal of engineering and mathematical sciences*. 1(1), P 1-7.
- Khoshnevisan, S., Wang, L., Juang, C.H. (2017). Response surface-based robust geotechnical design of supported excavation—spreadsheet-based solution. *Georisk: Assessment and management of risk for engineered systems and geohazards*. 11(1), 90-102.43.
- Kiki, T.Y., Cissé, I.K., and Favre, J.L. (2006). Plans d'expériences pour la stabilisation d'une argile gonflante du Bénin. *Revue française de géotechnique*. 114, P 33-41. 42.
- Kim, Y.S., and Kim, B.T. (2008). Prediction of relative crest settlement of concrete-faced rockfill dams analyzed using an artificial neural network model. *Comput. Geotech.* 35, P313–22.
- Kokutse, N.K., Temgoua, A.G.T., and Kavazović, Z. (2016). Slope stability and vegetation: Conceptual and numerical investigation of mechanical effects. *Ecological engineering (science direct)*. 86, P 146-153.
- Kolivand, F., and Rahmamejad, R. (2018). Estimation of geotechnical parameters using Taguchi's design of experiment (DOE) and back analysis methods based on field measurement data. *springer link*. 77, P 1763–1779.
- Konietzky, H., and Razavi, S. (2013). Optimization, sensitivity and robustness analysis—Applications and trends in geomechanics. *ISRM International Symposium, EUROCK*
- Lafifi, B., Rouaiguia, A., and Boumazza, N. (2019). Optimization of geotechnical parameters using Taguchi's design of experiment (DOE), RSM and desirability function. *Innov Infrastruct Solut*. 4(1), P1–12.

Références

- Leps, M. (2005). Single and Multi-Objective Optimization in Civil Engineering with applications. Thesis.
- Li, L., and Chu ,X.S .(2015). Multiple response surfaces for slope reliability analysis. Numer Anal Methods Geomech .39(2),P175–192.
- Li, J. H., and Wang, F. (2010). Study on the forecasting models of slope stability under data mining // Proceedings of the Workshop on Biennial International Conference on Engineering. Honolulu. 765.
- Liu, Z., Gilbert,G ., Cepeda,J.M ., and al .(2021). Modelling of shallow landslides with machine learning algorithms. Geoscience Frontiers (GSF) . V 12, Issue 1. P385-393.
- Lundstedt, T., Seifert, E., Abramo, L., and al. (1998). Experimental design and optimization. Chemometrics and intelligent laboratory systems, 42(1-2) ,P3–40.
- Luo. Z., Bui. X.N., Nguyen,H., and Moayed ,H. (2019). A novel artificial intelligence technique for analyzing slope stability using PSO-CA model. Eng Comput. 37(3), P1-12.
- Madic, M. J. and Radovanovic, M. R. (2011). Optimal selection of ANN training and architectural parameters using taguchi method: A case study. FME Transactions, 39(2), P79–86.
- McCombie, P., and Wilkinson, P. (2002). The use of the simple genetic algorithm in finding the critical factor of safety in slope stability analysis. Comput. Geotech. 29, P699–714.
- Meng, J., Mattsson, H., and Laue, J. (2021). Three-dimensional slope stability predictions using artificial neural networks. Numerical and Analytical Methods in Geomechanics. <https://doi.org/10.1002/nag.3252>.
- Mitchell, T.M. (1997). Machine Learning ,1-2. McGraw-Hill.
- Michelle, S. (2001). Réseaux de neurones. Support de cours.
- Mohan, S. V., Sirisha, K., and al. (2007). Bioslurry phase remediation of chlorpyrifos contaminated soil: Process evaluation and optimization by Taguchi design of experimental (DOE) methodology. Ecotoxicology and Environmental Safety, 68 ,P252–262.

Références

- Mohri, M., Rostamizaeh, A., and al. (2012). Foundations of machine learning. MIT press. (This source is used for both Machine Learning and Deep Learning), <https://lccn.loc.gov/2018022812>.
- Morgenstern, N.R., and Price, V.E. (1965). The analysis of the stability of general slip surfaces. *Géotechnique* .15, P79–93.
- Mousavi, S.M., Alavi, A.H., Gandomi, A.H., and Mollahasani,A. (2011). Nonlinear Genetic–Based Simulation of Soil Shear Strength Parameters. *J. Earth Syst. Sci.* 120(6), P1001–1022.
- Myers, R.H., and Montgomery, D.C. (2002). Response surface methodology, 2nd ed. Wiley & Sons (éditeurs), New York, NY, USA.
- Nansheng, Li., Bo, T., and Lihui,X . (2015). Slope Stability Analysis of Earth-Rockfill Dams Using MGA and UST. Hindawi Publishing Corporation. *Journal of Computational Engineering*. Vol 2015, Article ID 895142, P 10.
- Narendra, B.S., Sivapullaiah, P.V., Suresh, S. and Omkar, S.N. (2006). Prediction of unconfined compressive strength of soft grounds using computational intelligence techniques: A comparative study. *Comput. Geotech.* 33, P196–208.
- Nguyen, V. U. (1985). Determination of critical slope failure surface, *J. Geotech. Engrg., ASCE*. 111(2), P238-250.
- N, Janbu.,and al. (1973). Slope Stability Computations, Edited by R. C. Hirschfeld, & S. J. Poulos. Embankment Dam Engineering John Wiley.
- Olabi, A.G., Casalino, G., and al. (2006). An ANN and taguchi algorithms integrated approach to the optimization of co2 laser welding. *Advances in Engineering Software*, 37,10 ,P643–648.
- Peyronnard, O., and Benzaazoua, M. (2012). Alternative by-product-based binders for cemented mine backfill: Recipes optimisation using taguchi method. *Minerals Engineering*, 29, P28–38.
- Phadke, M. S. (1995). Quality engineering using robust design, ptr prentice-hall. Inc.,Englewood Cliffs, NJ.

Références

- Pham, K., Kim,D., and al.(2021). Ensemble learning-based classification models for slope stability analysis. *Catena journal*. V 196, 104886.
- Phung,V. H., and Rhee, E.J. (2019). A High-Accuracy Model Average Ensemble of Convolutional Neural Networks for Classification of Cloud Image Patches on Small Datasets, *MDPI journal*, 9(21), <https://doi.org/10.3390/app9214500>.
- Polat, S., and Sayan, P. (2019). Application of response surface methodology with a Box–Behnken design for struvite precipitation. *Advanced Powder Technology*. science direct. 30(10), P2396-2407.
- Polat, S.,and Sayan, P. (2019).Application of response surface methodology with a Box–Behnken design for struvite precipitation. *Adv Powder Technol* 30(10), 2396–2407.
- Pradhan, B., and Lee, S. (2010). Landslide susceptibility assessment and factor effect analysis: backpropagation artificial neural networks and their comparison with frequency ratio and bivariate logistic regression modelling. *Environ Modell Software*. sciences direct. 25, Issue 6, P 747-759.
- Qian, Z. G., Li, A.J, Chen W.C., and al. (2019). An artificial neural network approach to inhomogeneous soil slope stability predictions based on limit analysis methods. *Soils Found* .59(2), P556-569.
- Qi, C., and Tang, X. (2018). Slope stability prediction using integrated metaheuristic and machine learning approaches: A comparative study. *Comput Ind Eng*. 118, 112. doi: 0.1016/j.cie.2018.02.028.
- Quanpeng, Zhu. (2022). *Research on Slope Stability Analysis Based on Machine Learning*. Caibda. ISBN:978-3-8007-6025-1.
- Quinn, G. P., Keough, M. J., and al. (2002). *Experimental design and data analysis for biologists*. Cambridge University Press.
- Ranade,S.S .,and Thiagarajan, P .(2017).Selection of a design for response surface. In *IOP Conference Series: Materials Science and Engineering*. IOP Publishing 263(2),022043.

Références

- Ranganath, M. S., Vipin, Mishra, R. S., Prateek, and Nikhil. (2015). “Optimization of surface roughness in CNC turning of aluminium 6061 using Taguchi techniques”, *Inter. J. Modern Eng. Research (IJMER)*,5(5),42-50, ISSN: 2249–6645.
- Rani, C. S., and Rao, K. M. (2013). Statistical evaluation of compression index equations. *International journal of civil engineering and technology (IJCIET)*, 4(2), P104–117.
- Rao, R. S., Kumar, C. G., and al. (2008). The taguchi methodology as a statistical tool for biotechnological applications: a critical appraisal. *Biotechnology Journal: Healthcare Nutrition Technology*, 3(4), P510–523.
- Ray, A., Kumar, V., Kumar, A., and al. (2020). Stability prediction of Himalayan residual soil slope using artificial neural network. *Natural Hazards*. 103(3),3523-3540.
- Rouane, S., Rouane, N.E., Benyahia, M. S and al. (2019). Indentification par réseaux de neurone. Rapport de Projet de fin d'études. Université de M'Sila.
- Roul, A.R., Pradhan, S.P., and al. (2021). Investigation to slope instability along railway cut slopes in Eastern Ghats Mountain range, India: A comparative study based on slope mass rating, finite element modelling and probabilistic methods. *springer link*. <https://doi.org/10.1007/s12040-021-01711-1>.
- Sadeghi, S.H., Moosavi ,V., Karami, A., and al. (2012). Soil erosion assessment and prioritization of affecting factors at plot scale using the Taguchi method. *Journal of Hydrology*. 448–449 ,174–180.
- Sahin,E.K.(2020). Assessing the predictive capability of ensemble tree methods for landslide susceptibility mapping using XGBoost, gradient boosting machine, and random forest. *springer link*. 2, N°1308.
- Shahin, M. A., Jaksa, M. B. and Maier, H. R. (2001). Artificial Neural Network Application in Geotechnical Engineering, *Australian Geomechanics*,36(1), P49-62.70.
- Shahin, M.A., Maier, H. R., and Jaksa, M. B. (2002). Predicting Settlement of Shallow Foundations Using Neural Network, *J. of Geotech. & Geoenv. Engineering*. ASCE, Vol. 128(9), 785-79336.
- Shahin, M. A., Maier, H. R., and Jaksa, M. B. (2004). Data Division for Developing Neural Networks Applied to Geotechnical Engineering, *J. of Computing in Civil Engineering*. ASCE, Vol.18(2), 105-114. 72.

Références

- 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*, 8, P1-26.
- Sayed Ahmed, G.M., Sibghatullah Hussaini Quadri, S. and Mohiuddin, M.S. (2015). Optimization of feed and radial force in turning process by using Taguchi design approach” 4th International Conference on Materials Processing and Characterization (ICMPC), *Materials Today, Proceedings*, 2 ,3277 – 3285.
- Seitz, K.F., Grabe, J. (2016). Three-dimensional topology optimization for geotechnical foundations in granular soil. *Computers and Geotechnics*, 80(2016),41-48.
- Shahin, M. A., Jaksa, M. B. and Maier, H. R. (2001). Artificial Neural Network Application in Geotechnical Engineering, *Australian Geomechanics*, 36(1), P49-62. 70.
- Shahin, M.A., Maier, H. R., and Jaksa, M. B. (2002). Predicting Settlement of Shallow Foundations Using Neural Network, *J. of Geotech. & Geoenv. Engineering. ASCE*, Vol. 128(9), 785-79336.
- Shahin, M. A., Maier, H. R., and Jaksa, M. B. (2004). Data Division for Developing Neural Networks Applied to Geotechnical Engineering, *J. of Computing in Civil Engineering. ASCE*, Vol.18(2), 105-114. 72.
- 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*, 8, P1-26.
- Shahin, M.A. (2013). Artificial intelligence in geotechnical engineering: applications, modeling aspects, and future directions. *chez Metaheuristics in water, geotechnical and transport engineering, USA*. 169-204. Doi: 10.1016/B978-0-12-398296-4.00008-8.
- Shetty, R., Pai, R. B., Rao, S. S., and al. (2009). Taguchi’s technique in machining of metal matrix composites. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 31(1), P12–20.
- Shinoda, M., and Miyata, Y. (2019). PSO-based stability analysis of unreinforced and reinforced concrete slopes. *International Journal of Engineering Research & Technology (IJERT)*. ISSN: 2278-0181. 6 Issue 03.

Références

- Shiri, N. D., Bhat, S., Babisha, K., and al. (2016). Taguchi analysis on the compressive strength behavior of waste plastic-rubber composite materials. *American Journal of Materials Science*. 6 ,88–93. Reinforced soil slopes using non-circular slip surface. Springer link. vol 14, P 907–919.
- S.H. Li, L.Z. Wu, X.H. Luo. (2020). A novel method for locating the critical slip surface of a soil slope. *Engineering applications artificial intelligence*. Vol 94, 103733.
- Singh, D. N., Basudhar, P. K. (1992). A Note on the Optimal Lower bound Pull-out Capacity of Inclined Strip Anchor in Sand. *Canadian Geotechnical Engineering Journal*. Vol.29(5), P 870-873.
- Singh, J., Banka, H., and Verma, A. K. (2019). Locating critical failure surface using meta-heuristic approaches: a comparative assessment, Springer Link. Vol 12, N° 307.
- Spencer, E. (1967). A method of analysis of the stability of embankments assuming parallel inter-slice forces. *Géotechnique*. Vol 17, Issue 1, P 11-26.
- Sudhakara, D. and Prasanthib, G. (2014). “Application of Taguchi method for determining optimum surface roughness in wire electric discharge machining of P/M cold worked tool steel (Vanadis-4E)”, *Procedia Engineering*., 97,1565-1576.
- Sun,Y., Liu ,J., and al. (2010). Application of response surface methodology for optimization of polysaccharides production parameters from the roots of *Codonopsis pilosula* by a central composite design. *Carbohydrate Polymers*. science direct. 80, (3), 949-953.
- Taguchi, G. (1990). *Introduction to quality engineering*. McGraw-Hill, New York, USA, P 191.
- Taguchi, G., Chowdhury, S., and Wu, Y. (2005). *Taguchi’s quality engineering handbook*. Wiley.
- Tan, O., Zaimoglu, A. S., Hınıslioglu, S., and Altun, S. (2005). Taguchi approach for optimization of the bleeding on cement-based grouts. *Tunnelling and underground space technology*, 20(2) ,P167–173.
- Tan, O. (2006). Investigation of soil parameters affecting the stability of homogeneous slopes using the taguchi method. *Eurasian Soil Science*, 39,1248–1254.

Références

- Tsiampousi, A., Zdravkovic, L., and Potts, D.M. (2016). Numerical study of the effect of soil-atmosphere interaction on the stability and serviceability of cut slopes in London clay. *Canadian Geotechnical Journal*. <https://doi.org/10.1139/cgj-2016-0319@cgj-wgge.issue01>.
- Vapnik, V. (1995). *The Nature of Statistical Learning Theory*. Springer Verlag, New York, USA.
- Venkata Mohan, S., Chandrasekhara Rao, N., Krishna Prasad, K., and al. (2005). Anaerobic treatment of complex chemical wastewater in a sequencing batch biofilm reactor: Process optimization and evaluation of factor interactions using the taguchi dynamic doe methodology. *Biotechnology and Bioengineering*, 90(6), 732–745.
- Venkateswarlu, G., Davidson, M.J., and Tagore, G.R.N. (2010). Influence of process parameters on the cup drawing of aluminium 7075 sheet. *International Journal of Engineering Science and Technology*, 2, 41-49,
- Wan, H. (2017). *Gradient Descent Boosting: Convergence and Algorithm*. email: hwan3@illinois.edu.
- Wang, L., Wu, C., Tang, L., and al. (2020). Efficient reliability analysis of earth dam slope stability using extreme gradient boosting method. *springer link. Geotechnica*. vol 15, P 3135–3150.
- Yamagami, T., and Jiang, J. (1997). A search for the critical slip surface in three-dimensional slope stability analysis. *Sols and foundations (Japanese Geotechnical society)*. vol 37. N°3, 1-16.
- Yang, X.S. (2010). *Engineering optimization: an introduction with metaheuristic applications*, USA: John Wiley & Sons.
- Yang, X.S., and Koziel, S. (2011). *Computational optimization and applications in engineering and industry*, Germany. Springer Science & Business Media.
- Yang, X.S. (2013). *Optimization and metaheuristic algorithms in engineering*. chez Metaheuristic in Water Geotechnical and Transport Engineering. Elsevier, Waltham, 1-23. DOI: 10.1016/B978-0-12-398296-4.00001-5.

Références

- Yıldız, A., Öztürk, N., Kaya, N., and Öztürk, F. (2007). Hybrid multi-objective shape design optimization using taguchi's method and genetic algorithm. *Structural and Multidisciplinary Optimization*, 34,317–332.
- Yin, Z.Y., Jin, Y.F and al. (2017). Optimization techniques for identifying soil parameters in geotechnical engineering: Comparative study and enhancement. *Numerical and Analytical Methods in Geomechanics*. <https://doi.org/10.1002/nag.2714>.
- Yin, Z.Y., and Jin, Y.F. (2019). *Practice of Optimization Theory in Geotechnical Engineering*. Chapter Book, Springer.pp.1-7.
- Zangeneh N, Azizian A., and al. (2002). Application of response surface methodology in numerical geotechnical analysis. In *Proc. 55th Canadian Society for Geotechnical Conference*, Hamilton.
- Zaobao, Liu and al. (2014). An extreme learning machine approach for slope stability evaluation and prediction. *springer link*. V 73, pp 787–804.
- Zebarjadi Dana, H., Khaloo Kakaie, R., and al. (2018). Effects of geometrical and geomechanical properties on slope stability of open-pit mines using 2D and 3D finite difference methods. *Journal of Mining and Environment*. 9, Issue 4, P 785-1048. <https://doi.org/10.22044/jme.2018.7149.1562>.
- Zemouri, R. (2003). *Contribution à la surveillance des systèmes de production à l'aide des réseaux de neurones dynamiques : thèse*. Université de Franche-Comté.
- Zhang, F., Wang, Z., and Yang, M. (2015). Assessing the applicability of the taguchi design method to an interrill erosion study. *Journal of Hydrology*, 521. P65–73.
- Zhao, H. B. (2007). Reliability analysis of slope based on support vector machine. *Chin J Geotech Eng*. 29(6): 819 doi: 10.3321/j.issn:1000-4548.
- Zhou, X.P., and Cheng, H. (2013). Analysis of Stability of Three-Dimensional Slopes Using the Rigorous Limit Equilibrium Method, *Engineering Geology* 160, P.21-33.
- Zhou, J., Li, E., Yang,S., and al .(2019). Slope stability prediction for circular mode failure using gradient boosting machine approach based on an updated database of case histories. *Safety Science*. 118. 505-518. 24.

Références

Zhu, Q. (2022). Research on Slope Stability Analysis Based on Machine Learning. Caibda. ISBN :978-3-8007-6025-1.

Zidani, H. (2013). Représentation de solution en optimisation continue, multi-objectif et applications. Theses.hal.science. INSA de Rouen ; Université Mohammed V-Agdal (Rabat, Maroc), Français. NNT: 2013ISAM0027.

Zolfaghari, A. R., Heath, A. C., & McCombie, P. F. (2005). Simple genetic algorithm search for critical non-circular failure surface in slope stability analysis. Computers and geotechnics. 32(3), P 139-152.