

APPLICATION DES RESEAUX DE NEURONES ARTIFICIELS A LA PREDICTION DES RESULTATS D'ESSAIS PRESSIOMETRIQUES.

APPLICATION OF ARTIFICIAL NEURAL NETWORKS IN PREDICTION OF PRESSUREMETER TEST RESULTS.

Soufyane AISSAOUI¹, Mohammed el Amin BOUROUIS¹, Abdeldjalil ZADJAOUI¹
¹ Université Abou Bekr Belkaïd, Département de Génie Civil. Tlemcen- Algérie.
aissaouisoufyane@yahoo.fr / medamin_bourouis@yahoo.fr / a.zadjaoui@gmail.com

RÉSUMÉ – Cet article porte sur la proposition d'un modèle de prédiction des paramètres pressiométriques sur la base d'une approche neuronale par exploitation d'une base de données enrichie de paramètres géotechniques. Pour s'assurer de la fiabilité du modèle de prédiction choisi, les auteurs ont menés trois études en parallèles : régression simple, régression multiple et réseau neurone artificiel multicouches. Les auteurs discutent également les avantages et les limites de cette contribution.

ABSTRACT – This paper focuses on proposal of a model for predicting pressuremeter parameters based on a neural approach by exploiting a database enriched with geotechnical parameters. To ensure the reliability of the prediction model chosen, the authors conducted three studies in parallel: simple regression, multiple regression and a multi-layer artificial neural network. The authors also discuss the benefits and limitations of this contribution.

1. Introduction

L'étude du comportement des sols est complexe et nécessite le développement d'un grand nombre d'essais en laboratoire et en place (Mayne, 2012 ; Das, 2010). Les essais en place présentent l'avantage de tester le sol dans son environnement en évitant le remaniement du prélèvement nécessaires aux essais de laboratoire (Reiffsteck et al., 2012). Cela ne signifie pas pour autant que le sol puisse être considéré comme intact au moment de l'essai puisque la mise en place de l'appareil provoque soit un refoulement si l'appareil est foncé, soit une détente, s'il est mis en place dans un forage.

Les études en place, nécessitant un matériel le plus souvent encombrant et parfois lourd et sont basées surtout sur des considérations empiriques, manquant de fondements théoriques, à partir desquelles les propriétés des sols ne sont pas directement identifiées et dans lesquelles les chemins de contraintes effectives ou de déformations et les conditions aux limites spatiales correspondantes ainsi que les conditions de drainage sont généralement inconnues et toujours difficilement définissables.

Les essais de laboratoire présentent une meilleure maîtrise des conditions de drainage et de chargement et permettent d'explorer plus largement les lois de comportement des sols (Plumelle et al., 2013 ; Mayne et al., 2009), par contre ces essais souvent lents et généralement coûteux, s'effectuent sur des échantillons de petites tailles, plus ou moins remaniés et parfois non représentatifs de l'état du sol en place.

L'essai pressiométrique est un appareil très utilisé "in situ" dans certains pays, pour la plupart des projets géotechniques, en particulier pour les projets de fondation (Clarke, 1995 ; Amar et al., 1991). Le mode opératoire actuel est spécifié par la norme française NF EN ISO 22476-4 (AFNOR, 2005), et la norme américaine D 4719 (ASTM, 2007).

Parmi les informations qui peuvent être déduites directement de cet essai, on note en particulier le module pressiométrique E_M , la pression limite P_{LM} , et la pression de fluage P_f .

Cependant, certains chercheurs ont proposé des modèles d'estimation basés sur l'approche dite réseau de neurones artificiels. Ce travail se veut comme une proposition d'un modèle de prédiction de ces paramètres pressiométriques sur la base d'une approche neuronale par exploitation d'une base de données enrichie. Les résultats semblent intéressants pour une exploitation préliminaire dans la préparation de cahier de charges et surtout dans les études de faisabilité et d'avant-projet.

2. Matériels et méthodes


2.1. Pressiomètre Ménard : principe et résultats

La sonde est mise en place dans un avant-trou réalisé avant l'essai à la tarière à main ou avec d'autres moyens de forages, en fonction de la nature du sol, de sorte que les sols en place soient le moins remaniés possible et que le diamètre du forage puisse correspondre au mieux au diamètre de la sonde (Baguelin et al., 1978 ; Amar et al., 1991). L'appareil comprend : un contrôleur pression volume, une sonde, et des tubulures coaxiales.

Suivant la norme AFNOR (2005), l'essai consiste à appliquer progressivement par paliers sur la paroi du forage, une pression de pas constant Δp voisin du dixième de la pression limite estimée, chaque pression est maintenue pendant un instant $\Delta t = 60s$. A chaque palier, on enregistre la pression appliquée et le volume injecté dans la sonde à 1s, 15s, 30s et 60s.

L'interprétation classique consiste à tirer de cet essai : 1) un module pressiométrique E_M déterminé sur la partie linéaire de la phase pseudo-élastique (équation 1) ; 2) la pression limite p_{LM} qui correspond à la résistance de rupture du sol obtenue pour une grande déformation de la cavité cylindrique ; 3) la pression de fluage p_f qui correspond à la limite entre le comportement pseudo-élastique et l'état plastique, déterminée par la rupture de pente de la courbe de fluage donnant $V_{60}-V_{30}$ en fonction de p (courbe 2 figure 1).

$$E_M = 2(1 + \nu) \left[V_s + \left(\frac{V_1 + V_2}{2} \right) \right] \frac{(P_2 - P_1)}{(V_2 - V_1)} \quad (1)$$



2.2. Aperçu sur les réseaux de neurones artificiels (RNA)

L'application des réseaux neurones en géotechnique a considérablement évolué dans la dernière décennie, notamment pour la prévision des propriétés mécaniques du sol (Varghese et al., 2013; Bourouis et al., 2016). Un réseau neurone artificiel est un opérateur mathématique très simple, il cherche à approximer des fonctions non linéaires arbitraire, leur principe de base reposait sur l'apprentissage qui approche un phénomène à partir des couples entrée-sortie mesurée ou enregistrés sur un système. Les réseaux de

neurones utilisés dans la présente étude est de type perceptron multicouche (PMC), ce type est caractérisée par une structure bien particulière : ses neurones sont organisés en couches successives où les informations circulent dans un seul sens, de la couche d'entrée vers la couche de sortie, il s'agit donc d'une propagation directe (feed-forward). Les neurones d'une même couche ne sont pas interconnectés. Un neurone ne peut envoyer son résultat qu'à un neurone situé dans une couche postérieure. La valeur de la sortie résulte du calcul de la somme des entrées, pondérées par des coefficients dits de poids synaptiques. Un biais (0 ou 1) est additionné à la somme des entrées pondérées pour produire un résultat intermédiaire modulé par une fonction de transfert, puis transmis aux neurones de la couche de sortie. Son schéma de fonctionnement est donné sur la figure 2.

2.3. Présentation du site d'étude

La zone d'étude est située entre la wilaya de Boumerdès et Bordj Bou Arreridj en Algérie, c'est un projet qui comprend la réalisation, la modernisation et l'électrification d'une ligne ferroviaire à double voie sur une distance de 170 km.

2.3.1 Contexte Géomorphologique

La ligne traverse des reliefs montagneux à topographie accidentée impliquant des franchissements des obstacles par plusieurs tunnels, viaducs et des déblais importants.

2.3.2 Contexte Géologique

Sur le plan géologique local, le projet traverse la zone externe et la zone interne des Maghrébides. Les grands ensembles géologiques rencontrés le long du tracé, en partant de Bordj Bou Arreridj et en allant vers Thénia, (figure 3).

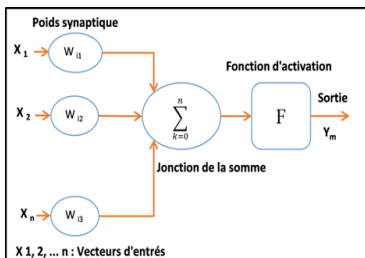


Figure 2. Modèle non linéaire RNA.




Figure 3. Aspect géologique du projet.

Nombreuses sont les recherches pour évaluer les dégâts engendrés par des séismes antérieurs. Il a été conclu que les dégâts n'ont pas vraiment atteint le site du projet à part quelques chutes de blocs dans les endroits montagneux. Paramètre exclu des entrées du modèle utilisé dans cette communication.

2.3.3 Contexte hydrogéologique

La carte hydrogéologique de l'Algérie du Nord, montre que la zone d'étude renferme plusieurs aquifères en allant de la commune de Thénia jusqu'à la commune de BBA. Deux principaux types d'aquifères ont été identifiés soit : 1) les aquifères continus, présentés dans notre tracé en nappe alluviale captive. 2) les aquifères discontinus à porosité de fissure et karstique, dont les vides sont constitués par des joints de stratification, des fissures ou des fractures interconnectées, rencontrés dans les formations à consistance rocheuse (marne de crétacé, calcaire, calcaire marneux et argilite).

2.4. Méthodologies

La méthodologie adoptée comporte une analyse de régression simple (RS) pour mettre en évidence l'existence des relations linéaires ou non linéaires significatives entre les paramètres d'entrée ($e_0, w_0, z, S_r, \rho_h, \rho_d, \rho_s$) et les paramètres de sortie (E_M, P_f, P_l). Ensuite, des modèles liants le module pressiométrique (E_M), la pression limite (P_l) et la

pression de fluage (P_f) aux paramètres physiques tel que : la profondeur (z), l'indice de vides (e_0), la teneur en eau naturel (w_0), degré de saturation (S_r), la masse volumique sèche (ρ_d) et la masse volumique des particules solides (ρ_s), ont été développés par la méthode de la régression multiple (RM). Cette méthode s'accompagne toujours d'un tableau d'analyse de variance. Ce tableau permettra de tester l'ensemble des variables explicatives et déduire la variance autour de l'équation de régression. Finalement, la technique Grid search a été retenue dans la méthode des réseaux neurones artificiels (RNA). Cette technique va nous permettre de tester une série de paramètres et de comparer les performances pour en déduire le meilleur paramétrage.

Dans cette étude nous avons utilisé une banque de données de 120 mesures. Le tableau 1 récapitule les plages de variation et les valeurs moyennes des paramètres mesurés.

Tableau 1. Valeurs moyennes des propriétés des sols utilisés.

Paramètres	Plage de variation	Moyenne
z (m)	[1 - 40]	11.9625
w_0 (%)	[6.25 - 47.2]	16.5168
S_r (%)	[25 - 125.37]	83.6974
ρ_s (Kg/m ³)	[2530 - 2840]	2668.442
ρ_h (Kg/m ³)	[1710 - 2440]	2090.817
e_0 (-)	[0.147 - 1.295]	0.5930
ρ_d (Kg/m ³)	[1220 - 2300]	1783.145
E_M (MPa)	[0.12 - 120.26]	29.4751
P_i (MPa)	[0.08 - 4.664]	1.8678
P_f (MPa)	[0.056 - 3.167]	1.0860

3. Résultats et discussions

3.1. Analyse par régression simple

Une analyse par régression simple a été effectuée. Il s'agit d'une analyse de distribution des points. Le but est de réduire le risque d'être dans un minimum local. Les équations obtenues sont mentionnées dans le tableau 2.

La corrélation simple est représentative pour les paramètres physiques à savoir la (z), (e_0), (w_0), (ρ_d) et (ρ_s) avec (E_m) et (P_i). Pour le degré de saturation la régression est moins significative voire faible. Cependant, pour la pression de fluage (P_f), seulement deux paramètres : (z) et (e_0) qui donnent une corrélation acceptable d'environ 20%. Les autres paramètres ne sont pas adaptés pour décrire la distribution des points. Ce qui nécessite une analyse par régression multiple pour répondre aux défaillances détectées dans la distribution des points.

3.2. Analyse de régression multiple (RM)

Les variables introduites dans notre modèle sont celles qui vont croître le coefficient de régression. L'ensemble de données utilisé, 105 observations avec 07 variables indépendantes. Le choix du modèle retenu est basé sur la racine carrée de l'erreur quadratique moyenne (RMSE). Les résultats obtenus sont résumés dans le tableau 3.

D'après le tableau 3, le modèle P_f nous a donné un coefficient de détermination (R^2) égale à 0.379, Cela signifie que le modèle mathématique utilisé n'explique absolument pas la distribution des points (37,9% uniquement). Cette faible valeur peut être expliquée par la présence d'un nombre important des variables qui n'ont pas une influence significative comme le montre le tableau 2. À propos de E_M et P_i une valeur proche de 60% a été obtenue, mais cela n'indique pas que le modèle vérifie les hypothèses nulles.

Tableau 2. Equations des paramètres pressiométriques en fonction de z , e_0 , w_0 , S_r , ρ_d , ρ_s .

Sortie (y)	Entrée (x)	Equations de régression simple	R ²
E_M (MPa)	e_0 (-)	$E_M = -26.63 \ln(e_0) + 10.931$	0.368
	w_0 (-)	$E_M = 52.322e_0^{-0.072w_0}$	0.231
	z (m)	$E_M = 2.0185 z + 5.3289$	0.470
	S_r (%)	$E_M = 0.361 S_r - 0.7435$	0.143
	ρ_d (kg/m ³)	$E_M = 0.0559 \rho_d - 70.182$	0.338
	ρ_s (kg/m ³)	$E_M = 2E+81 \rho_s^{-23.35}$	0.363
P_l (MPa)	e_0 (-)	$P_l = -1.209 \ln(e_0) + 1.026$	0.402
	w_0 (-)	$P_l = -1.223 \ln(w_0) + 5.1239$	0.284
	z (m)	$P_l = 0.0758 z + 0.9605$	0.352
	S_r (%)	$P_l = 0.0125 S_r + 0.8252$	0.090
	ρ_d (kg/m ³)	$P_l = 0.0026 \rho_d - 2.8114$	0.395
	ρ_s (kg/m ³)	$P_l = -17.82 \ln(\rho_s) + 142.47$	0.284
P_f (MPa)	e_0 (-)	$P_f = -0.454 \ln(e_0) + 0.7695$	0.168
	w_0 (-)	$P_f = 5.2447 w_0^{-0.692}$	0.198
	z (m)	$P_f = 0.0364 z + 0.6509$	0.240
	S_r (%)	$P_f = 0.0026 S_r + 0.8675$	0.012
	ρ_d (kg/m ³)	$P_f = 0.001 \rho_d - 0.6728$	0.165
	ρ_s (kg/m ³)	$P_f = -6.839 \ln(\rho_s) + 55.036$	0.124

Tableau 3. Analyse de régression multiple.

Indicateur statistique	E_M	P_l	P_f
R de corrélation	0.767	0.753	0.616
R ²	0.588	0.567	0.379
R ² ajustement	0.563	0.540	0.341
Erreur standard	18.383	0.819	0.570
Observations	105	105	105

C'est pour cela nous devons examiner d'autre vérification telle que le test de signification des coefficients du modèle. Ce test est réalisé par l'analyse de la variance. La valeur de F calculée est comparée avec une valeur théorique $F_{(\alpha)}$ tirée à partir des tables de Fisher pour un niveau de signification $\alpha=0.01$ donné et pour deux degrés de liberté k_1 et k_2 . Si la valeur de $F \geq F_{(\alpha)}$, l'hypothèse nulle est automatiquement rejetée ce qui donne alors les coefficients de régression significativement différents de zéro. Dans le cas contraire le modèle n'est pas significatif et par conséquent il est considéré comme mauvais.

Pour les trois paramètres E_m , P_l et P_f , les valeurs de F sont supérieures à la valeur de F critique qui égale à 2.06. Selon les résultats d'ANOVA (tableau 4), F de signification est largement inférieure à 0 pour les trois modèles. Donc pour chaque modèle au moins l'un des coefficients est statistiquement significatif au niveau de confiance et apporte une contribution sur l'ensemble du modèle. Les modèles de régression multiple obtenus sont donnés par les équations suivantes 2,3 et 4.

$$E_M = 1.55 \times z - 2.72 \times w_0 + 0.68 \times S_r - 0.09 \times \rho_s - 0.022 \times \rho_h + 52.97 \times e_0 - 0.022 \times \rho_d + 288.42 \quad (2)$$

$$P_l = 0.05 \times z - 0.15 \times w_0 + 0.03 \times S_r - 0.004 \times \rho_s - 0.001 \times \rho_h + 2.89 \times e_0 - 0.001 \times \rho_d + 13.65 \quad (3)$$

$$P_f = 0.03 \times z - 0.09 \times w_0 + 0.018 \times S_r - 0.002 \times \rho_s - 0.0005 \times \rho_h + 1.92 \times e_0 - 0.001 \times \rho_d + 8.90 \quad (4)$$

3.3. Analyse par Réseaux de Neurones Artificiels (RNA)

L'ensemble des données utilisées pour le développement des modèles de RNA sont divisées en deux parties: un ensemble pour l'apprentissage (105 mesures) et un ensemble pour le test (15 mesures). Nous avons ensuite procédé à une normalisation de chaque vecteur entré et cible. Ce traitement des données est effectué à l'aide du module

«sklearn preprocessing». Le réseau choisi pour cette étude est un Feed-Forward de type perceptron multicouches avec un algorithme d'optimisation adaptatif 'Adam'. Cet algorithme calcul des taux d'apprentissage individuels pour différents paramètres, il est conçu spécialement pour la formation de réseaux de neurone profond.

Pour ajuster les paramètres et obtenir une performance optimale nous avons utilisé la fonction « Grid search ». Cette fonction elle fait varier le nombre de neurones et les fonctions de transfert dans les couches cachées (fonctions logsigmoïde, tangente sigmoïde et linéaire), afin d'optimiser et d'affiner le modèle à retenir. Pour éviter le sur apprentissage nous avons ajouté une couche de dropout qui consiste à désactiver aléatoirement une certaine proportion lors de l'apprentissage du modèle. Après plusieurs essais, les réseaux de neurones proposés sont des réseaux à quatre couches: Une couche d'entrée composée de huit neurones correspondant au type du sol, (z), (e_0), (w_0), (S_r), (ρ_h), (ρ_d) et (ρ_s), deux couches cachées et une couche de sortie (figures 3). Le paramétrage est donné dans le tableau 5.

Tableau 4. Analyse de variance (ANOVA).

Paramètres		Coefficients	Stand. Error	T Stat	P-value	F (calcul)	F($\alpha=0.01$) théorique
E_M (MPa)	Constant	288.4181	103.5160	2.7862	0.0063	22.8713	5.3910⁻¹⁹
	z	1.5504	0.2343	6.6166	1.3110 ⁻⁹		
	w_0	-2.7246	1.0772	-2.5293	0.0128		
	S_r	0.6845	0.3248	2.1078	0.0373		
	ρ_s	-0.0880	0.0289	-3.0425	0.0029		
	ρ_h	-0.0224	0.0297	-0.7551	0.4518		
	e_0	52.9745	26.4951	1.9994	0.0480		
	ρ_d	-0.0221	0.0264	-0.8385	0.4036		
P_I (MPa)	Constant	13.6512	4.6119	2.9600	0.0038	20.9410	8.5310⁻¹⁸
	z	0.0492	0.0104	4.7110	7.13.10 ⁻⁶		
	w_0	-0.1472	0.0480	-3.0674	0.0027		
	S_r	0.0327	0.0145	2.2587	0.0258		
	ρ_s	-0.0041	0.0013	-3.1903	0.0018		
	ρ_h	-0.0010	0.0013	-0.7484	0.4558		
	e_0	2.8858	1.1804	2.4447	0.0161		
	ρ_d	-0.0008	0.0012	-0.6414	0.5226		
P_f (MPa)	Constant	8.9026	3.2092	2.7741	0.0065	9.7864	1.80.10⁻⁹
	z	0.0304	0.0073	4.185262	5.6910 ⁻⁵		
	w_0	-0.0910	0.0334	-2.72364	0.0075		
	S_r	0.0178	0.0101	1.765734	0.0802		
	ρ_s	-0.0025	0.0009	-2.78134	0.0064		
	ρ_h	-0.0005	0.0009	-0.54018	0.5901		
	e_0	1.9224	0.8214	2.340382	0.0210		
	ρ_d	-0.0009	0.0008	-1.10395	0.2720		

Tableau 5. Erreurs absolues moyennes de test et validation.

Sortie	Entrée	Architecture	Batch	Itér.	Prob.	Test	
						R ²	RMSE
E_M (MPa)	Type du sol, z , w_0 , S_r , ρ_s , ρ_h , e_0 , ρ_d .	8-50-50-1	10	1000	0.3	0.9934	2.7211
P_I (MPa)	Type du sol, z , w_0 , S_r , ρ_s , ρ_h , e_0 , ρ_d .	8-100-100-1	20	500	0.4	0.9829	0.1762
P_f (MPa)	Type du sol, z , w_0 , S_r , ρ_s , ρ_h , e_0 , ρ_d .	8-100-50-1	20	500	0.2	0.9354	0.2020

Les performances ont été évaluées avec RMSE et R². La comparaison des performances du réseau développé dans cette communication avec la base de test est montrée sur les figures (7-a, 8-a et 9-a), On constate un alignement parfait des résultats simulés par le réseau E_M et P_I autour de la bissectrice (figures 7-b et 8-b), ce qui est en

cohérence avec les valeurs des coefficients de détermination ($R^2 \approx 1$). Dans le cas de P_f , on note une certaine dispersion des données (figures 8-b). Cela probablement est dû à l'utilisation des paramètres qui n'ont pas une influence sur la pression de fluage. La comparaison des résultats estimés par RNA et les résultats mesurés a permis de conclure de la fiabilité du modèle et de son pouvoir prédictif.




Figure 7-a. Comparaison entre mesure et prédiction (RNA).




Figure 8-a. Comparaison entre mesure et prédiction (RNA).




Figure 9-a. Comparaison entre mesure et prédiction (RNA).




Figure 7-b. Performances du modèle E_M




Figure 8-b. Performances du modèle P_i .




Figure 9-b. Performances du modèle P_f

3.4. Comparaison des résultats

Les performances des deux modèles utilisés pour la prédiction sont résumées dans le tableau 6 à l'aide de paramètre RMSE et le coefficient de détermination.

L'étude montre que l'analyse par RNA donne des résultats plus précis pour la prédiction du module pressiométrique E_M . Le réseau neurone artificiel a donné une erreur sept fois inférieure à celle de la régression multiple. Cela prouve que la topologie de deux couches cachées et le nombre de neurones adoptés a été choisi soigneusement.

La prédiction de la pression limite P_i est plus fiable par rapport à la régression multiple est ceux malgré le nombre restreint des variables d'entrée. En effet, des études similaires ont montrées que, plus on augmente le nombre d'entrées plus le modèle peut reproduire une meilleure performance (Patel et Desai, 2010).

Pour la pression de fluage P_f , la comparaison des résultats estimés par les réseaux de neurones avec la régression multiple nous a permis de conclure sur la fiabilité du modèle et de leur pouvoir prédictif. Cependant, des améliorations peuvent être apportées pour garantir une meilleure prédiction, comme par exemple l'utilisation d'une base de données plus large et plus représentative avec un nombre d'entrées suffisant.

4. Conclusion

Les principales conclusions tirées sont les suivantes :

- ❖ Les résultats de la prévision obtenus en utilisant le modèle neuronal, à partir ; de la nature du sol, (z), (e_0), (w_0), (ρ_d), (ρ_s) et (S_r), montrent une très bonne concordance expliquée par un coefficient de détermination R^2 significatif qui dépasse 0,93 et une faible erreur quadratique moyenne.
- ❖ Il est connu que le comportement des sols présente une variabilité spatiale, pour cela il est toujours préférable d'augmenter le nombre des paramètres influant dans les modèles, ce qui assure la sécurité de prédiction.
- ❖ L'utilisation d'un nombre important des paramètres rend un apprentissage plus correct et par conséquent augmente les informations disponibles pour les réseaux.

- ❖ L'analyse par le RNA manque de transparence ; la sortie est obtenue sous forme de valeurs numériques. Aucune information ne peut être recueillie sur l'effet de chaque entrée sur la sortie. Pour l'analyse de régression, la sortie obtenue sous forme d'équations ou lignes de tendance nous donne une idée globale sur l'influence de chaque variable d'entrée sur la prédiction.

Tableau 6. Comparaison entre le modèle RNA et RM paramètre E_M .

Type du sol	z (m)	w_0 (%)	S_r (%)	ρ_s (kg/m ³)	ρ_h (kg/m ³)	e_0	ρ_d (kg/m ³)	Mesuré	RM	RNA
								E_M (MPa)		
MDG	32	9.39	118.4	2606	2400	0.206	2190	76.6430	72.7865	78.2359
AP	6	10.2	38.6	2675	1900	0.706	1550	16.7000	21.4127	14.3714
ASG	2	10.56	97.98	2580	2280	0.278	2060	19.0370	20.7754	14.2679
MCG	22	8.95	112.92	2530	2390	0.200	2190	99.8460	61.3271	102.561
SLG	9	28	96.85	2660	1969	0.769	1526.36	52.1000	21.0754	46.9637
ASG	4	10.56	97.98	2580	2280	0.278	2060	19.1660	23.8762	15.2572
SL	10	8.9	36	2826	1750	0.698	1640	6.6400	17.0303	7.24659
DASGG	6	11.27	84.85	2580	2190	0.342	1960	22.1120	23.6730	22.1858
MDG	36	9.39	118.4	2606	2400	0.206	2190	75.2440	78.9880	80.1913
LSPP	8.5	21.1	88.5	2840	2050	0.680	1690	0.8300	7.3879	1.76535
DASGG	22	10.17	102.85	2580	2310	0.255	2100	54.9280	53.4044	55.6441
AS	14	23.2	72.6	2655	1970	0.848	1590	3.3300	28.4994	4.20505
AM	12	26.3	94	2655	1950	0.742	1540	30.8500	27.5394	31.0779
LPM	11.5	47.2	100	2790	1790	1.295	1220	0.5900	1.9981	1.84979
LSPP	7.5	21.1	88.5	2840	2050	0.680	1690	0.1300	5.8375	1.77003
RMSE									14.9606	2.7211
R²									0.7888	0.9934

Tableau 7. Comparaison entre le modèle RNA et RM paramètre P_f .

Type du sol	z (m)	w_0 (%)	S_r (%)	ρ_s (kg/m ³)	ρ_h (kg/m ³)	e_0	ρ_d (kg/m ³)	Mesuré	RM	RNA
								P_f (MPa)		
MDG	32	9.39	118.4	2606	2400	0.206	2190	3.4900	3.5640	3.4420
AP	6	10.2	38.6	2675	1900	0.706	1550	1.2400	1.6943	1.3429
ASG	2	10.56	97.98	2580	2280	0.278	2060	0.5620	1.7804	0.5089
MCG	22	8.95	112.92	2530	2390	0.200	2190	4.0690	3.2631	4.1771
SLG	9	28	96.85	2660	1969	0.769	1526.36	1.9200	1.3183	1.9070
ASG	4	10.56	97.98	2580	2280	0.278	2060	0.6820	1.8788	0.6988
SL	10	8.9	36	2826	1750	0.698	1640	1.6800	1.4339	1.2745
DASGG	6	11.27	84.85	2580	2190	0.342	1960	2.7540	1.7926	2.5016
MDG	36	9.39	118.4	2606	2400	0.206	2190	3.4700	3.7608	3.4607
LSPP	8.5	21.1	88.5	2840	2050	0.680	1690	0.3200	0.8359	0.4441
DASGG	22	10.17	102.85	2580	2310	0.255	2100	3.2330	2.8544	3.2352
AS	14	23.2	72.6	2655	1970	0.848	1590	0.2500	1.6778	0.4441
AM	12	26.3	94	2655	1950	0.742	1540	2.3500	1.5740	1.9666
LPM	11.5	47.2	100	2790	1790	1.295	1220	0.3500	0.1089	0.4441
LSPP	7.5	21.1	88.5	2840	2050	0.680	1690	0.4200	0.7868	0.4441
RMSE									0.7507	0.1762
R²									0.6811	0.9829

Tableau 8. Comparaison entre RNA et le RM paramètre P_f .

Type du sol	z (m)	w_0 (%)	S_r (%)	ρ_s (kg/m ³)	ρ_h (kg/m ³)	e_0	ρ_d (kg/m ³)	P_f (MPa)		
								Mesuré	RM	RNA
MDG	32	9.39	118.4	2606	2400	0.206	2190	1.8030	1.8514	1.6293
AP	6	10.2	38.6	2675	1900	0.706	1550	0.8680	1.1837	1.1808
ASG	2	10.56	97.98	2580	2280	0.278	2060	0.2740	0.8501	0.4063
MCG	22	8.95	112.92	2530	2390	0.200	2190	2.7810	1.6730	2.4770
SLG	9	28	96.85	2660	1969	0.769	1526.36	1.1700	0.8371	0.9670
ASG	4	10.56	97.98	2580	2280	0.278	2060	0.2930	0.9109	0.4541
SL	10	8.9	36	2826	1750	0.698	1640	1.1760	0.9785	0.7936
DASGG	6	11.27	84.85	2580	2190	0.342	1960	0.9910	0.9317	1.2855
MDG	36	9.39	118.4	2606	2400	0.206	2190	1.7760	1.9730	1.7005
LSPP	8.5	21.1	88.5	2840	2050	0.680	1690	0.2240	0.4928	0.1804
DASGG	22	10.17	102.85	2580	2310	0.255	2100	1.6140	1.4850	1.6294
AS	14	23.2	72.6	2655	1970	0.848	1590	0.1750	1.1009	0.3790
AM	12	26.3	94	2655	1950	0.742	1540	1.6450	0.9899	1.5532
LPM	11.5	47.2	100	2790	1790	1.295	1220	0.2450	0.2749	0.2357
LSPP	7.5	21.1	88.5	2840	2050	0.680	1690	0.2940	0.4624	0.1670
RMSE									0.4926	0.2020
R²									0.6038	0.9354

5. Références bibliographiques

- AFNOR (2005). Essai pressiométrique Ménard – Partie 1 – Essai sans cycle. Norme NF P94-110-1, Reconnaissance et essais, 43 pages.
- Amar S., Clarke B.G., Gambin M.P., Orr T.L.L. (1991). The application of pressuremeter test results to foundation design in Europe, European Regional Technical Committee N°4, Pressuremeters, A.A Balkema, Ed., pp. 1-24.
- ASTM D4719 (2007). Standard Test Method for Prebored Pressuremeter Testing in Soils. annual book of ASTM standards, Section 4, V. 04.08.
- Baguelin F., Jézéquel J.F., Shield D.H. (1978). The pressuremeter and foundation engineering. Transtech publications, 618 pages.
- Bourouis M.A., Zadjajou A., Djedid A. (2016). Neuro-genetic approach for immersed CBR index prediction, In: Proceedings of the First Southern African Geotechnical Conference, CRC Press, 2016, pp. 143-148. doi: 10.1201/b21335-27.
- Clarke B.G. (1995). Pressuremeters in geotechnical design. Blackie Academic and Professional, London, 364 pages.
- Das B.M. (2010). Principles of geotechnical engineering (7th edition). Cengage Learning, Stamford, CT, 688 pages.
- Mayne P.W. (2012). SOA Report : Geotechnical Site Characterization in the Year 2012 and Beyond. State-of-the-Art and Practice in Geotechnical Engineering. GSP 226, GeoCongress, Oakland, CA, ASCE Press, Reston, Virginia, pp. 157-186.
- Mayne P.W., Coop M.R., Springman S., Huang A.B., Zornberg J. (2009). State-of-the-Art Paper (SOA-1): Geomaterial Behavior and Testing. Proc. 17th Intl. Conf. Soil Mechanics & Geotechnical Engineering, Vol. 4 (ICSMGE, Alexandria, Egypt), pp. 2777-2872.
- Patel R., Desai M. (2010). CBR Predicted by index properties of soil for alluvial soils of South Gujarat. Indian Geotechnical Conference, vol. I, p. 79–82.
- Plumelle C., Cui Y.J., Fabre D., Fouche O., Hirshauer A., Tabbagh A. (2013). Théorie et pratique de la géotechnique. Editions Le Moniteur, 999 pages.
- Reiffsteck P., Lossy D., Benoît J. (2012). Forages, sondages, et essais in situ Géotechniques : les outils pour la reconnaissance des sols et des roches. 1 vols. Paris, France, Presse des Ponts, 796 pages.
- Varghese V., Babu S., Bijukumar R., Cyrus S., Abraham B M. (2013). Artificial Neural Networks: A Solution to the Ambiguity in Prediction of Engineering Properties of Fine-Grained Soils. Geotech Geol Eng, vol. 31, n°4, p. 1187-1205.