



Modélisation et optimisation multicritère des fondations sur sols renforcés par réseaux de neurones artificiels : validation, robustesse et compromis coût–performance géotechnique

^{1,1}RANDRIAKOTONIRINA Minolalaina Derasoa, ^{1,2}TOVONIRINA Mamiharizo Jackie,
^{1,3}RAKOTOSON Andriatiana Tolontsoa, ^{1,4}RAJAONARISON Eddie Franck

¹Ecole Doctorale Ingénierie et Géosciences - Université d'Antananarivo

RESUME : Cette étude développe une démarche de modélisation et d'optimisation multicritère des fondations sur sols renforcés à l'aide de réseaux de neurones artificiels, en intégrant simultanément les performances géotechniques, la robustesse prédictive et le coût relatif. L'analyse considère la largeur de fondation B , la profondeur relative de renforcement u/B , la pression appliquée et plusieurs paramètres mécaniques du sol. Le modèle de démonstration présente une forte concordance entre valeurs observées et prédites, avec $R^2 = 0,970$, $RMSE = 0,141$ et $MAE = 0,112$, tandis que le biais moyen des résidus reste proche de $-0,006$. L'importance relative atteint 23 % pour B , 20 % pour u/B et 18 % pour la pression appliquée. La validation croisée sur dix plis fournit un R^2 moyen de 0,931, avec des coefficients de variation de 2,3 % pour R^2 , 8,6 % pour le $RMSE$ et 10,1 % pour le MAE . L'analyse multicritère identifie un compromis autour de $B = 1,39$ m et $u/B = 0,35$, correspondant à un tassement voisin de 1,2 cm pour un indice de coût proche de 2,1. Ces résultats illustrent l'intérêt du RNA pour rechercher des solutions conciliant portance, maîtrise des tassements, stabilité prédictive et économie.

Mots-clés : Réseaux de neurones artificiels ; Optimisation multicritère ; Fondations renforcées ; Validation croisée ; Compromis coût–performance.

ABSTRACT: This study develops a multicriteria modeling and optimization approach for foundations on reinforced soils using artificial neural networks, simultaneously integrating geotechnical performance, predictive robustness, and relative cost. The analysis considers foundation width B , relative reinforcement depth u/B , applied pressure, and several mechanical soil parameters. The demonstration model shows a strong agreement between observed and predicted values, with $R^2 = 0.970$, $RMSE = 0.141$, and $MAE = 0.112$, while the mean residual bias remains close to -0.006 . The relative importance reaches 23% for B , 20% for u/B , and 18% for the applied pressure. Ten-fold cross-validation yields a mean R^2 of 0.931, with coefficients of variation of 2.3% for R^2 , 8.6% for $RMSE$, and 10.1% for MAE . The multicriteria analysis identifies a trade-off around $B = 1.39$ m and $u/B = 0.35$, corresponding to a settlement of approximately 1.2 cm and a cost index close to 2.1. These results highlight the potential of artificial neural networks (ANNs) to identify solutions that balance bearing capacity, settlement control, predictive stability, and cost-effectiveness.

Keywords: Artificial neural networks; Multicriteria optimization; Reinforced foundations; Cross-validation; Cost–performance trade-off.

Digital Object Identifier (DOI): <https://doi.org/10.5281/zenodo.22829507>

1 Introduction

Le dimensionnement des fondations sur sols de faibles à moyennes caractéristiques mécaniques demeure une problématique centrale en ingénierie géotechnique, car il doit satisfaire simultanément les exigences de capacité portante, de tassement admissible, de stabilité et de coût. Le recours au renforcement du sol permet d'améliorer le comportement du massif sous fondation en modifiant la distribution des contraintes, en augmentant la rigidité apparente de la zone sollicitée et en limitant les déformations verticales. L'efficacité de ces techniques dépend cependant de plusieurs paramètres interdépendants, notamment la largeur de la fondation, la profondeur relative du renforcement, les propriétés mécaniques du sol et le niveau de chargement appliqué [1]. Cette multiplicité de facteurs rend difficile l'identification d'une configuration optimale par des approches exclusivement déterministes. Les méthodes classiques de calcul fournissent des bases indispensables pour vérifier la sécurité des fondations, mais elles deviennent rapidement itératives lorsque plusieurs variables doivent être ajustées simultanément. Dans le cas des sols renforcés, la recherche d'un compromis entre amélioration de la capacité portante, réduction des tassements et limitation du coût conduit naturellement à une formulation multicritère du problème. Les concepts de dominance et de front de Pareto offrent alors un cadre adapté pour comparer plusieurs solutions non dominées sans réduire arbitrairement tous les objectifs à un indicateur unique [2]. Cette approche est particulièrement pertinente pour les bâtiments économiques, où une amélioration supplémentaire de la performance géotechnique ne se justifie que si elle reste compatible avec les contraintes de matériaux, d'exécution et de coût. Parallèlement, les réseaux de neurones artificiels ont progressivement été introduits en géotechnique afin de représenter des relations complexes et non linéaires entre paramètres d'entrée et réponses mécaniques [3]. Leur intérêt réside dans leur capacité à apprendre à partir d'ensembles de données et à fournir des prédictions rapides une fois le modèle entraîné. Des applications aux fondations superficielles ont notamment montré leur potentiel pour l'estimation des tassements, paramètre souvent déterminant dans le dimensionnement en service [4]. Toutefois, la performance prédictive seule ne suffit pas à garantir l'utilité d'un modèle. La robustesse, la stabilité vis-à-vis de la partition des données, l'analyse des résidus et la cohérence de l'influence des variables doivent également être examinées afin de réduire le risque de surapprentissage et d'améliorer la confiance accordée aux prédictions [5]. Dans cette perspective, la présente étude propose une démarche intégrée de modélisation et d'optimisation multicritère du système fondation-sol renforcé par réseau de neurones artificiels. L'approche considère conjointement les paramètres géométriques de la fondation, la position relative du renforcement, les caractéristiques du sol, les sollicitations appliquées et un indicateur de coût. La méthodologie repose sur l'apprentissage d'un modèle neuronal, sa validation statistique et croisée, l'analyse de la sensibilité des variables puis l'exploration de solutions selon plusieurs objectifs géotechniques et économiques. L'utilisation d'une validation croisée vise à apprécier la capacité de généralisation du modèle sur différentes partitions des données [6]. L'objectif final est de disposer d'un outil d'aide à la décision capable d'orienter le dimensionnement vers des configurations conciliant sécurité géotechnique, maîtrise des tassements, efficacité du renforcement et rationalisation du coût.

2 Matériels et méthodes

2.1 Matériels

La réalisation de cette étude a reposé sur la constitution d'une base de données géotechniques, le traitement numérique des informations collectées et le développement d'un modèle par réseau de neurones artificiels destiné à la prédiction et à l'optimisation du comportement des fondations sur sols renforcés. La collecte des données a été effectuée à partir de documents techniques et scientifiques disponibles, notamment des rapports géotechniques, des résultats d'essais de laboratoire et in situ, des plans et documents de fondation, des tableaux de dimensionnement ainsi que des publications scientifiques consacrées aux fondations superficielles et aux techniques de renforcement des sols. Les informations ont été sélectionnées en fonction de leur pertinence pour la caractérisation du système sol-fondation et de leur possibilité d'être converties en variables numériques exploitables par le modèle. Les données extraites ont été regroupées dans des tableaux structurés avant leur intégration dans l'environnement de calcul. Les principales variables considérées comprenaient la largeur de la fondation B , la profondeur relative du renforcement u/B , la pression appliquée, la cohésion du sol c , l'angle de frottement interne ϕ , le poids volumique γ , le module de déformation E ainsi qu'un indice relatif associé au coût de la solution. Les paramètres de sortie comprenaient notamment la capacité portante admissible, le tassement et

les indicateurs nécessaires à l'évaluation de la performance du système fondation–renforcement. Les données provenant de différentes sources ont été harmonisées afin de conserver des unités cohérentes et une structure homogène. Les valeurs manquantes, les doublons et les observations présentant des incohérences évidentes ont été contrôlés avant la phase de modélisation. L'ensemble du traitement informatique a été réalisé avec le langage Python, retenu en raison de sa large utilisation en calcul scientifique et en apprentissage automatique. La bibliothèque NumPy a été employée pour les opérations numériques, la manipulation des vecteurs et matrices ainsi que la préparation des tableaux nécessaires aux calculs scientifiques [7]. La bibliothèque Pandas a été utilisée pour importer, organiser, nettoyer, filtrer et regrouper les données provenant des différentes sources documentaires, les fichiers de travail étant principalement conservés sous des formats tabulaires compatibles avec CSV et les feuilles de calcul [8]. Avant l'apprentissage du réseau de neurones, les variables numériques ont été préparées afin d'éviter que les différences d'échelle entre les paramètres géotechniques n'influencent excessivement le processus d'apprentissage. Les opérations de séparation des données, de normalisation et d'évaluation statistique ont été réalisées à l'aide de Scikit-learn [9]. La base a été divisée en ensembles destinés à l'apprentissage, à la validation et au test. Une validation croisée en plusieurs plis a également été retenue afin d'apprécier la stabilité du modèle lorsque la composition des ensembles d'apprentissage et de validation varie. Les indicateurs de performance considérés comprenaient notamment le coefficient de détermination R^2 , le RMSE et le MAE, complétés par l'analyse des résidus et la variabilité des performances entre les plis. Le modèle prédictif a été développé sous TensorFlow, environnement permettant la construction et l'entraînement de réseaux de neurones artificiels [10]. Un réseau neuronal de type perceptron multicouche à propagation avant a été retenu. La couche d'entrée recevait les variables géotechniques et économiques sélectionnées, tandis que plusieurs couches cachées entièrement connectées assuraient l'apprentissage des interactions entre les paramètres. La couche de sortie était adaptée à la grandeur géotechnique à prédire. Le processus d'apprentissage a été suivi simultanément sur les données d'entraînement et de validation afin d'identifier la zone de convergence et de limiter le risque de surapprentissage. L'évolution de la fonction de perte a été enregistrée au cours des époques afin de déterminer le point à partir duquel une prolongation de l'apprentissage n'apportait plus d'amélioration significative. Après validation, le modèle a été utilisé comme outil de prédiction pour explorer plusieurs combinaisons de largeur B et de profondeur relative u/B. Les sorties ont été exploitées pour construire des surfaces de réponse représentant le tassement, la capacité portante et l'indice de coût relatif. Une démarche d'optimisation multicritère a ensuite été appliquée afin de comparer les configurations possibles et d'identifier les solutions non dominées constituant le front de Pareto. Cette approche permet de rechercher un compromis entre réduction du tassement, amélioration de la capacité portante et limitation du coût, plutôt que d'optimiser séparément un seul critère. Les représentations graphiques ont été produites avec Matplotlib, utilisé pour générer les courbes d'apprentissage, les diagrammes de validation croisée, les distributions des erreurs, les surfaces de réponse, les représentations de sensibilité et les graphiques de compromis coût–performance [11]. Les figures ont été préparées en haute résolution afin d'assurer leur lisibilité et leur intégration dans un format de publication scientifique. L'ensemble de cette chaîne de traitement, depuis la collecte documentaire jusqu'à l'optimisation multicritère, a ainsi permis d'organiser les données géotechniques dans un environnement numérique reproductible et de mettre en place un cadre d'aide à la décision fondé sur les prédictions du réseau de neurones artificiels.

2.2 Méthodes

La démarche méthodologique adoptée a été organisée autour d'une succession d'étapes comprenant la préparation des données, la construction du modèle neuronal, son apprentissage, sa validation, l'analyse de l'influence des variables et l'optimisation multicritère du système fondation–sol renforcé. Après la constitution et le contrôle de la base de données géotechniques, les variables d'entrée ont été sélectionnées de manière à représenter les principaux facteurs susceptibles d'influencer la réponse du système. Elles comprenaient notamment la largeur de la fondation B, la profondeur relative du renforcement u/B, la pression appliquée, la cohésion du sol c, l'angle de frottement interne ϕ , le poids volumique γ , le module de déformation E ainsi qu'un indice de coût. Les sorties du modèle ont été définies en fonction des objectifs de l'étude, principalement le tassement, la capacité portante admissible et les indicateurs nécessaires à l'évaluation technico-économique des solutions. Avant l'apprentissage, les données ont été mélangées et réparties entre ensembles d'entraînement, de validation et de test. Les variables numériques ont été normalisées afin de réduire l'influence des différences d'échelle entre les paramètres géotechniques. Cette étape était particulièrement importante puisque certaines variables étaient exprimées en

mètres, d'autres en kilopascals ou sous forme de rapports sans dimension. La normalisation a ainsi permis de présenter au réseau des variables comparables sur le plan numérique et de favoriser la stabilité du processus d'apprentissage. Le modèle prédictif retenu était un réseau de neurones artificiels de type perceptron multicouche à propagation avant. Cette architecture a été choisie pour sa capacité à représenter les relations non linéaires existant entre les caractéristiques du sol, la géométrie de la fondation, les conditions de renforcement et les réponses géotechniques. Le réseau était constitué d'une couche d'entrée correspondant aux variables sélectionnées, de plusieurs couches cachées entièrement connectées et d'une couche de sortie destinée à restituer les grandeurs recherchées. Des fonctions d'activation non linéaires ont été utilisées dans les couches cachées afin de permettre au réseau d'apprendre des interactions complexes. L'initialisation des paramètres internes a été conduite selon les principes visant à maintenir une propagation stable des informations et des gradients au cours de l'entraînement, conformément aux recommandations relatives aux réseaux neuronaux à propagation avant [12]. L'apprentissage du réseau a reposé sur un processus itératif de rétropropagation des erreurs. À chaque époque, les prédictions produites par le modèle ont été comparées aux valeurs de référence présentes dans la base d'apprentissage, puis les paramètres internes du réseau ont été progressivement ajustés afin de réduire les erreurs. L'algorithme Adam a été retenu pour l'optimisation des paramètres du modèle en raison de son adaptation automatique du processus d'apprentissage et de son efficacité pour l'entraînement de réseaux comportant un nombre important de paramètres [13]. L'évolution de la fonction de perte a été enregistrée séparément pour les données d'entraînement et de validation. La comparaison de ces deux courbes a servi à contrôler la convergence du modèle et à identifier l'apparition éventuelle d'un surapprentissage. Le nombre d'époques a ainsi été limité à la zone dans laquelle la performance de validation cessait de s'améliorer de manière significative. La capacité prédictive du modèle a ensuite été évaluée en comparant les valeurs observées aux valeurs estimées par le réseau. Cette validation a été complétée par l'examen du coefficient de détermination R^2 , de l'erreur quadratique moyenne RMSE et de l'erreur absolue moyenne MAE. L'analyse des résidus a également été utilisée pour vérifier la présence éventuelle d'une surestimation ou d'une sous-estimation systématique. La distribution des erreurs autour de zéro a permis d'apprécier visuellement le biais du modèle et d'identifier les observations pour lesquelles les écarts entre prédictions et valeurs de référence étaient les plus importants. Afin de ne pas limiter l'évaluation des performances à une seule séparation de la base de données, une validation croisée en dix plis a été adoptée. La base a été divisée successivement en dix sous-ensembles, chacun étant utilisé à son tour pour la validation tandis que les autres participaient à l'apprentissage. Cette procédure a permis d'obtenir plusieurs valeurs de R^2 , RMSE et MAE et d'apprécier ainsi la stabilité du réseau lorsque la composition des ensembles de données variait. L'utilisation d'une validation croisée en dix plis constitue une approche reconnue pour obtenir une estimation plus robuste de la capacité de généralisation d'un modèle que celle reposant sur une seule partition des données [14]. La moyenne des performances et leur coefficient de variation ont ensuite été utilisés comme indicateurs de robustesse inter-plis. Une analyse de sensibilité a parallèlement été réalisée afin d'identifier les variables jouant le rôle le plus important dans les prédictions du réseau. L'influence relative de la largeur B , du rapport u/B , de la pression appliquée et des paramètres mécaniques du sol a été comparée après normalisation des niveaux d'importance. Cette étape avait pour objectif de vérifier que la réponse du modèle restait compatible avec les mécanismes physiques attendus et d'identifier les paramètres prioritaires pour la phase d'optimisation. Les résultats de cette analyse ont également permis de limiter l'interprétation du réseau comme une simple boîte noire en fournissant une lecture de la contribution relative des variables d'entrée. Après validation du modèle, le réseau a été utilisé comme modèle de substitution pour explorer rapidement un grand nombre de configurations fondation-renforcement. Des combinaisons successives de largeur B et de profondeur relative u/B ont été générées dans le domaine étudié, puis le RNA a été sollicité pour prédire le tassement et la capacité portante correspondant à chacune d'elles. Un indice de coût relatif a parallèlement été associé aux différentes solutions afin de représenter l'incidence économique de l'augmentation des dimensions de la fondation et du niveau de renforcement. Cette exploration a permis de produire les surfaces de réponse représentant les variations du tassement, de la capacité portante et du coût dans l'espace des paramètres de conception. La dernière étape a reposé sur une approche d'optimisation multicritère fondée sur le principe de dominance de Pareto. Les configurations ont été comparées simultanément en considérant la réduction du tassement, le maintien d'une capacité portante satisfaisante et la limitation du coût. Une solution était considérée comme non dominée lorsqu'aucune autre configuration ne permettait d'améliorer un critère sans détériorer au moins un autre objectif. Les solutions ainsi retenues ont constitué le front de Pareto, qui représente non pas une solution optimale unique, mais un ensemble de compromis

techniquement pertinents. Cette démarche est cohérente avec les principes des algorithmes d'optimisation multi-objectifs tels que NSGA-II, fondés sur le classement des solutions non dominées et la conservation d'une diversité de compromis [15]. Une solution de compromis a finalement été sélectionnée à proximité de la zone offrant conjointement un faible tassement, un coût maîtrisé et une capacité portante compatible avec les exigences géotechniques. L'ensemble de cette méthodologie permet ainsi d'utiliser le réseau de neurones non seulement comme outil de prédiction, mais également comme modèle numérique de substitution intégré à une procédure d'aide à la décision. La combinaison de l'analyse des erreurs, de la validation croisée, de l'étude de sensibilité, des surfaces de réponse et de l'analyse de Pareto permet d'évaluer successivement la précision, la robustesse, l'interprétabilité et la capacité d'optimisation du modèle avant son application au dimensionnement du système fondation-sol renforcé.


3 Résultats et discussions

3.1 Résultats

3.1.1 Indicateurs dérivés pour l'optimisation géotechnique des fondations et du renforcement des sols

La figure 1 suivant présente quatre indicateurs complémentaires dérivés des résultats géotechniques précédemment obtenus afin de mieux apprécier les possibilités d'optimisation du système sol-fondation. Elle met simultanément en évidence la concentration des solutions de fondation recommandées, le gain relatif associé à la profondeur du renforcement, le bénéfice marginal produit par l'élargissement de la semelle et la stabilité de la réduction du tassement sous différents niveaux de pression. Ces indicateurs permettent de dépasser une lecture uniquement descriptive des résultats et d'identifier les paramètres présentant le plus grand intérêt pour la modélisation et l'optimisation par réseaux de neurones artificiels.

Figure 1: Indicateurs dérivés pour l'optimisation géotechnique des fondations et du renforcement des sols



Source : Auteur 2026

Interprétation


La figure (a) montre, sous forme de diagramme de Pareto, que les solutions de fondation sont fortement concentrées sur les catégories superficielles. Les semelles isolées représentent à elles seules 1 380 cas sur 2 200, soit environ 62,7 % des recommandations. L'ajout des 380 cas de semelles filantes ou longrines porte le pourcentage cumulé à 80,0 %. Les radiers, avec 320 cas, conduisent ensuite à un cumul proche de 94,5 %, tandis que les 120 fondations profondes complètent les 5,5 % restants. Cette distribution montre que deux catégories seulement regroupent quatre cinquièmes des configurations étudiées, ce qui confirme l'importance des fondations

superficielles dans la recherche de solutions adaptées aux bâtiments économiques. La figure (b) exprime l'efficacité du renforcement sous forme de gain relatif par rapport à un sol non amélioré. Pour une profondeur très faible, le gain est limité à environ 20 %, puis il augmente rapidement avec le rapport u/B . Il atteint approximativement 72 % vers $u/B = 0,20$, 100 % à $u/B = 0,25$ et dépasse 110 % entre $u/B = 0,30$ et $u/B = 0,40$. Le maximum est observé autour de $u/B = 0,35$, avec un gain voisin de 120 %. La plage $0,25 \leq u/B \leq 0,50$ apparaît ainsi comme la zone la plus favorable. Au-delà, le bénéfice diminue fortement pour atteindre environ 40 % à $u/B = 0,60$, 10 % à $u/B = 0,70$ et devenir presque nul lorsque u/B approche 1,00. Ce comportement confirme qu'une profondeur intermédiaire est préférable à un renforcement systématiquement plus profond. La figure (c) analyse le gain marginal de capacité portante associé à l'augmentation de la largeur de la fondation. Les valeurs évoluent approximativement entre 85 et 100 kPa/m selon les intervalles de largeur considérés, avec une moyenne proche de 92,4 kPa/m. Des gains élevés, voisins de 100 kPa/m, sont notamment observés autour de certaines largeurs intermédiaires, tandis que les valeurs les plus faibles restent de l'ordre de 85 à 86 kPa/m. Cette variation relativement limitée indique que l'élargissement de la fondation produit un bénéfice globalement régulier sur la capacité portante dans la plage étudiée. Toutefois, la présence d'un gain positif ne signifie pas qu'un élargissement systématique soit économiquement optimal, puisque l'augmentation de la largeur entraîne parallèlement une consommation supplémentaire de béton, d'armatures et de terrassement. Enfin, la figure (d) montre que l'efficacité du renforcement vis-à-vis du tassement reste remarquablement stable lorsque la pression augmente de 50 à 300 kPa. La réduction relative est d'environ 44 % à 50 kPa, puis elle se maintient autour de 39 à 40 % pour les pressions comprises entre 100 et 300 kPa. La valeur moyenne obtenue est proche de 40,3 %. Cette stabilité suggère que le renforcement conserve une efficacité significative sur une large plage de sollicitations, sans perte importante de performance aux niveaux de charge élevés. Pris ensemble, ces quatre indicateurs montrent que l'optimisation doit rechercher simultanément une solution de fondation économiquement pertinente, une profondeur de renforcement proche de la zone optimale, une largeur suffisante sans surdimensionnement et une réduction durable des tassements. Ils constituent ainsi des variables particulièrement utiles pour orienter l'apprentissage et la prise de décision d'un modèle fondé sur les réseaux de neurones artificiels.

3.1.2 Validation statistique et analyse de sensibilité du modèle géotechnique par réseaux de neurones artificiels

La figure 2 ci-après présente les principaux indicateurs utilisés pour apprécier la qualité prédictive et le comportement du modèle par réseaux de neurones artificiels. Elle regroupe la comparaison entre valeurs observées et prédites, l'analyse des résidus, l'importance relative des variables d'entrée et la distribution des erreurs. Ces représentations permettent d'évaluer simultanément la précision globale du modèle, l'existence éventuelle de biais systématiques et la contribution des paramètres géotechniques à la prédiction. Les valeurs présentées sur cette figure étant des données de démonstration destinées à tester la méthodologie graphique, elles devront être remplacées par les sorties réelles du modèle avant toute publication.

Figure 2: Validation statistique et analyse de sensibilité du modèle géotechnique par réseaux de neurones artificiels



Source : Auteur 2026


Interprétation

La figure (a) montre une forte concordance entre les valeurs observées et prédites, la majorité des points étant distribuée à proximité de la droite de concordance 1:1. Dans cette démonstration, le coefficient de détermination atteint $R^2 = 0,970$, ce qui signifie que le modèle reproduit environ 97 % de la variabilité des observations. L'erreur quadratique moyenne RMSE est de 0,141, tandis que l'erreur absolue moyenne MAE est de 0,112. L'écart relativement faible entre ces deux indicateurs suggère l'absence d'un nombre important d'erreurs extrêmes et traduit une précision globalement homogène sur l'étendue des valeurs considérées. La figure (b) complète cette analyse par l'examen des résidus, définis ici comme la différence entre les valeurs prédites et observées. Les points restent globalement répartis de part et d'autre de la ligne correspondant à un résidu nul, sans tendance systématique marquée lorsque la valeur prédite augmente. Les moyennes calculées par classes demeurent également proches de zéro, généralement comprises entre environ -0,04 et +0,03. Une telle répartition serait, avec des données réelles, indicative d'un modèle ne présentant ni surestimation ni sous-estimation systématique importante. Quelques résidus ponctuels atteignent cependant des valeurs proches de $\pm 0,40$, ce qui rappelle la nécessité d'examiner les configurations pour lesquelles les prédictions sont moins précises. La figure (c) présente l'importance relative normalisée des variables utilisées par le modèle. Dans cette démonstration, la largeur de la fondation B constitue le paramètre le plus influent avec 23 %, suivie de la profondeur relative du renforcement u/B avec 20 % et de la pression appliquée avec 18 %. La cohésion c contribue à hauteur de 12 %, tandis que l'angle de frottement ϕ représente 10 %. Le poids volumique γ et le module E présentent respectivement des contributions de 7 % et 6 %, alors que l'indice de coût intervient à hauteur de 4 %. Cette hiérarchie suggère que les paramètres directement liés à la géométrie de la fondation, au positionnement du renforcement et au niveau de chargement exercent une influence majeure sur la réponse estimée. Elle reste néanmoins à confirmer à partir du modèle entraîné sur les données géotechniques réelles. La figure (d) montre une distribution des erreurs globalement centrée autour de zéro et proche d'une forme normale. Le biais moyen est très faible, avec une valeur d'environ -0,006, ce qui correspond, dans cette démonstration, à une légère sous-estimation pratiquement négligeable à l'échelle des prédictions. La majorité des résidus se concentre approximativement entre -0,20 et +0,20, tandis que les valeurs situées au-delà de $\pm 0,30$ restent peu fréquentes. Pris ensemble, ces indicateurs constituent une démarche cohérente de validation d'un modèle neuronal appliqué à l'optimisation géotechnique. Lorsque ces analyses seront reproduites avec les sorties réelles du réseau, elles permettront de vérifier que les prédictions présentent simultanément une forte concordance avec les observations, un faible niveau d'erreur, un biais limité et une hiérarchie des variables compatible avec le comportement physique attendu du système sol-fondation.

3.1.3 Optimisation multicritère du système fondation–renforcement à partir des prédictions du réseau de neurones artificiels

La figure 4 suivant présente une analyse multicritère destinée à identifier les configurations de fondation et de renforcement offrant le meilleur compromis entre tassement, capacité portante et coût relatif. Les surfaces de réponse obtenues à partir du modèle neuronal permettent d'examiner simultanément l'influence de la largeur de fondation B et de la profondeur relative du renforcement u/B sur les performances géotechniques. La dernière représentation complète cette analyse par un front de Pareto permettant de distinguer les solutions dominées des configurations offrant le meilleur compromis coût–performance. Les valeurs représentées ici étant issues d'une démonstration de la méthodologie, elles devront être remplacées par les prédictions réelles du RNA avant toute publication scientifique.

Figure 3: Optimisation multicritère du système fondation–renforcement à partir des prédictions du réseau de neurones artificiels



Source : Auteur 2026

Interprétation


La figure (a) montre que le tassement prédit varie fortement avec la combinaison de B et de u/B . Les valeurs les plus élevées, proches de 3,0 à 3,3 cm, apparaissent principalement pour les faibles largeurs de fondation associées à des profondeurs relatives importantes, notamment lorsque B est voisin de 0,8 à 1,0 m et u/B supérieur à environ 0,70. À l'inverse, une zone de tassement minimal, comprise approximativement entre 0,9 et 1,2 cm, apparaît pour des largeurs voisines de 2,5 à 3,7 m et pour une profondeur relative située autour de $u/B = 0,30$ à 0,40. Cette zone correspond au voisinage de la profondeur optimale identifiée précédemment et confirme que l'efficacité du renforcement dépend simultanément de son positionnement et de la géométrie de la fondation. La figure (b) présente la surface de capacité portante admissible prédite. Celle-ci évolue approximativement de 350 à 750 kPa sur le domaine étudié. Les valeurs les plus faibles sont obtenues pour les petites largeurs de fondation, particulièrement lorsque B reste inférieur à environ 1,2 m. L'augmentation de B entraîne une croissance progressive de la capacité portante, tandis qu'une zone favorable apparaît également autour de $u/B = 0,30$ à 0,45. Pour les largeurs proches de 3,5 à 4,0 m et une profondeur relative voisine de 0,35, la capacité prédite peut atteindre environ 700 à 750 kPa dans cette simulation. La surface confirme ainsi que l'élargissement de la fondation et un positionnement adéquat du renforcement peuvent agir conjointement pour améliorer la résistance du système sol–fondation. La figure (c) met cependant en évidence la contrepartie économique de cette amélioration. L'indice de coût relatif varie approximativement de 1,2 à 6,0 et augmente principalement avec la largeur B . Les configurations

de faible largeur présentent les coûts relatifs les plus réduits, tandis que les fondations proches de 4,0 m conduisent aux valeurs les plus élevées. L'influence de u/B sur le coût apparaît plus modérée, même si certaines profondeurs peuvent entraîner une augmentation liée au volume de matériau de substitution, au renforcement et aux opérations de mise en œuvre. Cette évolution montre qu'une solution présentant une capacité portante maximale ou un tassement minimal n'est pas nécessairement la plus avantageuse économiquement. Enfin, la figure (d) synthétise cette problématique à travers le compromis entre l'indice de coût et le tassement prédit. Le nuage de solutions évaluées révèle qu'une réduction progressive du tassement nécessite généralement une augmentation du coût. Le front de Pareto regroupe les configurations pour lesquelles il n'est plus possible d'améliorer un objectif sans dégrader l'autre. La solution de compromis mise en évidence correspond, dans cette démonstration, à une largeur d'environ $B = 1,39$ m et à une profondeur relative $u/B = 0,35$. Elle conduit à un tassement proche de 1,2 cm pour un indice de coût voisin de 2,1. Cette configuration ne correspond ni au coût minimal ni au tassement minimal, mais représente un équilibre entre performance géotechnique et dépense relative.

3.1.4 Robustesse, convergence et validation croisée du modèle géotechnique par réseau de neurones artificiels

La figure 4 ci-dessous présente les principaux indicateurs permettant d'évaluer la stabilité et la fiabilité du modèle par réseau de neurones artificiels au cours de l'apprentissage et de la validation croisée. Elle regroupe l'évolution des courbes d'apprentissage, les coefficients de détermination obtenus sur plusieurs plis de validation, les erreurs associées à chaque pli ainsi qu'un indicateur synthétique de stabilité inter-plis. L'ensemble de ces représentations permet d'apprécier à la fois la convergence du modèle, la qualité de généralisation de ses prédictions et la régularité de ses performances. Comme l'indique la figure, les valeurs illustrées sont ici des données synthétiques de démonstration et devront être remplacées par les résultats réels du modèle avant publication.

Figure 4: Robustesse, convergence et validation croisée du modèle géotechnique par réseau de neurones artificiels



Source : Auteur 2026

Interprétation

La figure (a) montre que la fonction de perte diminue régulièrement au cours des itérations aussi bien pour l'ensemble d'entraînement que pour l'ensemble de validation. La courbe d'entraînement passe approximativement de 0,92 au début de l'apprentissage à près de 0,06 en fin de processus, tandis que la courbe de validation évolue d'environ 1,02 vers 0,09. La proximité des deux courbes sur l'ensemble de l'intervalle traduit une convergence globalement stable, sans divergence importante entre apprentissage et validation. L'époque optimale indiquée

autour de 170 suggère qu'à partir de ce niveau, le modèle atteint un compromis satisfaisant entre amélioration de l'ajustement et limitation du surapprentissage. La figure (b) présente les valeurs de R^2 obtenues pour 10 plis de validation croisée. Les coefficients restent élevés et relativement homogènes, variant approximativement entre 0,89 et 0,95, avec une moyenne de 0,931. Les meilleurs résultats apparaissent pour certains plis proches de 0,95, tandis que les plus faibles restent voisins de 0,89. Cette dispersion modérée indique que le modèle conserve une bonne capacité explicative quelle que soit la partition des données, ce qui constitue un signe favorable de robustesse. La figure (c) complète cette analyse par les erreurs de prédiction par pli. Les valeurs de RMSE s'étendent approximativement de 0,134 à 0,185, alors que les valeurs de MAE varient d'environ 0,103 à 0,139. Les deux indicateurs demeurent relativement proches d'un pli à l'autre, ce qui confirme une précision assez régulière du modèle. Les plis présentant les erreurs les plus élevées ne s'écartent pas fortement du niveau moyen, ce qui suggère l'absence d'instabilités majeures ou de sensibilité excessive à certaines partitions de l'échantillon. La figure (d) synthétise la stabilité inter-plis au moyen du coefficient de variation. Celui-ci est d'environ 2,3 % pour R^2 , 8,6 % pour le RMSE et 10,1 % pour le MAE. La très faible variabilité du coefficient de détermination montre que la qualité globale d'ajustement reste particulièrement stable. Les coefficients de variation un peu plus élevés observés pour les erreurs restent néanmoins modérés et traduisent une dispersion acceptable.

3.2 Discussions

La démarche adoptée met en évidence l'intérêt d'associer modélisation neuronale et optimisation multicritère pour analyser simultanément les performances géotechniques et économiques du système fondation-sol renforcé. La validation du modèle à partir de plusieurs indicateurs permet d'évaluer sa capacité à reproduire les réponses observées tout en contrôlant les erreurs de prédiction. L'analyse des résidus et la validation croisée renforcent cette appréciation en vérifiant que les performances ne dépendent pas uniquement d'une partition particulière des données et que le modèle conserve une stabilité satisfaisante lors des différentes phases d'apprentissage. L'étude de sensibilité apporte également une dimension importante à l'interprétation du réseau, puisqu'elle permet d'identifier les paramètres les plus influents dans les prédictions. La largeur de la fondation, la profondeur relative du renforcement et la pression appliquée apparaissent ainsi comme des variables majeures dans la réponse du système, ce qui reste cohérent avec le comportement physique attendu d'une fondation sur sol renforcé. Cette cohérence est essentielle pour limiter l'utilisation du réseau comme simple outil de prédiction non interprétable. L'intérêt principal de l'approche réside toutefois dans l'exploitation du RNA comme modèle de substitution pour tester rapidement un grand nombre de configurations. Les surfaces de réponse permettent de visualiser les zones associées aux faibles tassements, aux capacités portantes élevées et aux coûts relatifs maîtrisés. L'analyse de Pareto montre qu'il n'existe pas nécessairement une solution unique optimale, mais plutôt plusieurs compromis entre performance géotechnique et coût. Cette caractéristique est particulièrement adaptée au dimensionnement des fondations, où une amélioration supplémentaire de la sécurité ou de la rigidité peut entraîner une augmentation importante des dépenses. Ainsi, l'association entre validation statistique, analyse de sensibilité et optimisation multicritère constitue une démarche cohérente pour orienter le choix vers des solutions de fondation rationnelles. Elle permet de réduire les essais successifs de dimensionnement tout en conservant une lecture géotechnique des résultats. L'application à des données réelles et plus diversifiées restera néanmoins déterminante pour confirmer la capacité de généralisation du modèle et renforcer son utilisation comme outil d'aide à la décision.

4 Conclusion

La présente étude montre que l'intégration des réseaux de neurones artificiels à une démarche d'optimisation multicritère constitue une approche pertinente pour le dimensionnement des fondations sur sols renforcés. Le modèle permet de relier plusieurs paramètres géotechniques et géométriques aux réponses du système, tout en évaluant la qualité des prédictions par des indicateurs de performance, l'analyse des résidus et la validation croisée. L'analyse de sensibilité met en évidence l'importance de variables telles que la largeur de la fondation, la profondeur relative du renforcement et la pression appliquée. L'exploitation du RNA comme modèle de substitution permet ensuite d'explorer rapidement de nombreuses configurations et d'identifier des zones favorables du point de vue du tassement, de la capacité portante et du coût relatif. L'analyse de Pareto complète cette démarche en mettant en évidence plusieurs solutions de compromis plutôt qu'une optimisation fondée sur un seul critère. Cette approche offre ainsi un cadre d'aide à la décision capable de concilier performance géotechnique, robustesse prédictive et maîtrise économique. Son application à des bases de données réelles plus étendues permettra de renforcer la généralisation du modèle et d'envisager son utilisation comme outil pratique pour l'optimisation des fondations sur sols renforcés.

REFERENCES

- [1] . S. Kommu, C. Pranay, P. Prashanthi, C. Vamshi and P. Sravanth, "Geosynthetic Reinforced Soil (GRS) Foundation: A Review of Bearing Capacity and Settlement Behaviour Studies," *Journal of Physics: Conference Series*, vol. 2779, 012062, 2024, doi: 10.1088/1742-6596/2779/1/012062.
- [2] K. Deb, A. Pratap, S. Agarwal and T. Meyarivan, "A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II," *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 2, pp. 182–197, 2002, doi: 10.1109/4235.996017.
- [3] M. A. Shahin, M. B. Jaksa and H. R. Maier, "Artificial Neural Network Applications in Geotechnical Engineering," *Australian Geomechanics Journal*, vol. 36, no. 1, pp. 49–62, 2001.
- [4] M. A. Shahin, H. R. Maier and M. B. Jaksa, "Predicting Settlement of Shallow Foundations Using Neural Networks," *Journal of Geotechnical and Geoenvironmental Engineering*, vol. 128, no. 9, pp. 785–793, 2002, doi: 10.1061/(ASCE)1090-0241(2002)128:9(785).
- [5] M. A. Shahin, M. B. Jaksa and H. R. Maier, "Recent Advances and Future Challenges for Artificial Neural Systems in Geotechnical Engineering Applications," *Advances in Artificial Neural Systems*, vol. 2009, Article ID 308239, pp. 1–9, 2009, doi: 10.1155/2009/308239.
- [6] R. Kohavi, "A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection," *Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence (IJCAI)*, vol. 2, pp. 1137–1145, 1995.
- [7] C. R. Harris, K. J. Millman, S. J. van der Walt et al., "Array programming with NumPy," *Nature*, vol. 585, pp. 357–362, 2020, doi: 10.1038/s41586-020-2649-2.
- [8] W. McKinney, "Data Structures for Statistical Computing in Python," in *Proceedings of the 9th Python in Science Conference*, pp. 56–61, 2010.
- [9] F. Pedregosa, G. Varoquaux, A. Gramfort et al., "Scikit-learn: Machine Learning in Python," *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.
- [10] M. Abadi, P. Barham, J. Chen et al., "TensorFlow: A System for Large-Scale Machine Learning," in *12th USENIX Symposium on Operating Systems Design and Implementation (OSDI 16)*, pp. 265–283, 2016.
- [11] J. D. Hunter, "Matplotlib: A 2D Graphics Environment," *Computing in Science & Engineering*, vol. 9, no. 3, pp. 90–95, 2007, doi: 10.1109/MCSE.2007.55.
- [12] X. Glorot and Y. Bengio, "Understanding the Difficulty of Training Deep Feedforward Neural Networks," *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics*, vol. 9, pp. 249–256, 2010. Cette étude traite notamment de l'initialisation et de la stabilité de l'apprentissage des réseaux à propagation avant.
- [13] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," *International Conference on Learning Representations (ICLR)*, 2015. Adam repose sur une optimisation adaptative des paramètres et est conçu pour être efficace avec des problèmes comportant de nombreux paramètres.
- [14] R. Kohavi, "A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection," *Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence*, pp. 1137–1145, 1995. L'étude examine notamment l'utilisation de la validation croisée en dix plis pour l'estimation des performances et la sélection de modèles.
- [15] K. Deb, A. Pratap, S. Agarwal and T. Meyarivan, "A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II," *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 2, pp. 182–197, 2002, doi: 10.1109/4235.996017. Cette référence formalise une méthode d'optimisation multi-objectifs fondée sur le classement des solutions non dominées et la recherche d'un ensemble de solutions de Pareto.