

# Prédiction de la stabilité des talus par apprentissage automatique

## Slope Stability Prediction with Machine Learning

Selmane LEBDAOUI<sup>1\*</sup>, Gilles CHAPRON<sup>1</sup>, Marc HUERTA<sup>1</sup>, Tatiana RICHA<sup>1</sup>

<sup>1</sup> Terrasol-Setec, Paris, France

\*[selmane.lebdaoui@setec.com](mailto:selmane.lebdaoui@setec.com)

**RESUME :** Cet article propose une nouvelle approche pour accélérer l'évaluation de la stabilité des talus en s'appuyant sur une méthode d'intelligence artificielle. Ce travail s'inscrit dans le cadre du développement d'un module expérimental intégré à la plateforme web **Orbow**, permettant de prédire instantanément le facteur de sécurité et la surface de rupture d'un talus simple (pente unique, sol homogène) à partir d'un métamodèle entraîné sur des données générées avec **Talren**, logiciel de référence développé par **Terrasol**. Le métamodèle repose sur des techniques d'apprentissage automatique, en particulier des algorithmes ensemblistes à base d'arbres de décision (*XGBoost*, *LightGBM*, *ExtraTrees*). Il a été entraîné sur un jeu de données comprenant plus de 15 000 configurations générées automatiquement via **Talren**, couvrant un large domaine de paramètres géométriques et mécaniques. L'article détaillera la démarche adoptée pour construire ce métamodèle et évaluera la capacité des différents algorithmes testés à apprendre efficacement le comportement du système étudié.

**ABSTRACT:** The purpose of this article is to present a new approach to accelerate slope stability assessment by leveraging artificial intelligence tools. This work is part of the development of an experimental module integrated into **Orbow** web platform, enabling instantaneous prediction of the factor of safety and the failure surface of a simple slope (single incline, homogeneous soil) using a surrogate model trained on simulated data generated with **Talren**, a reference software developed by **Terrasol**. The surrogate model relies on machine learning techniques, particularly ensemble algorithms based on decision trees (*XGBoost*, *LightGBM*, *ExtraTrees*). It was trained on a dataset of more than 15,000 configurations automatically generated via **Talren**, covering a wide range of geometric and mechanical parameters. The article will detail the adopted methodology to build this metamodel and will assess the ability of the different algorithms tested to effectively learn the behavior of the system under study.

**Mots-clés :** Stabilité des pentes, Machine Learning, apprentissage supervisé, métamodèle, méthode des tranches, Talren

## 1 INTRODUCTION

La stabilité des talus constitue une problématique centrale en ingénierie géotechnique, tant pour la conception que pour la sécurité des ouvrages. Les méthodes classiques de calcul fondées sur l'équilibre limite et la recherche de la surface de rupture critique offrent une grande précision, mais elles peuvent s'avérer coûteuses en temps de calcul, sensibles aux choix de paramétrage et pas toujours optimales pour les besoins d'évaluation rapide en phases amont (études de faisabilité, criblage de variantes). Dans ce contexte, la création d'outils d'estimations fiables et instantanées constitue une opportunité intéressante pour orienter efficacement la prise de décision.

L'objectif du travail présenté ici est de créer un métamodèle fondé sur l'apprentissage machine afin d'approximer les calculs **Talren** pour un talus simple : pente unique et sol homogène. En s'appuyant sur des algorithmes ensemblistes à base d'arbres de décision et sur un jeu de données généré automatiquement avec **Talren**, le métamodèle vise à prédire instantanément

le facteur de sécurité et à reconstituer la surface de rupture, tout en limitant la saisie de paramètres. Ce modèle n'a évidemment pas vocation à remplacer les méthodes de référence mais seulement à les compléter en fournissant une réponse rapide et suffisamment robuste pour les premières étapes des projets.

L'article présente brièvement la génération des données et les choix de modélisation, puis la définition des exercices d'apprentissage, avant de décrire les résultats obtenus et d'en discuter les limites et perspectives.

## 2 METHODOLOGIE ET GENERATION DES DONNEES

### 2.1 Présentation du logiciel **Talren** et automatisation des calculs

**Talren** est un logiciel de référence pour l'analyse de stabilité des talus. L'utilisateur commence par définir la géométrie du massif en traçant l'enveloppe du terrain et en positionnant les points qui délimitent les

couches de sol. À chaque couche, on associe ensuite ses paramètres mécaniques essentiels : le poids volumique  $\gamma$ , la cohésion  $c$  et l'angle de frottement interne  $\varphi$ .

Pour dérouler un calcul manuel de recherche de la surface critique, **Talren** permet de spécifier un éventail de surfaces de glissement à explorer en définissant les points (ou intervalles) d'entrée et de sortie sur les plateaux amont et aval. Le logiciel calcule alors le facteur de sécurité  $Fs$  pour chaque surface testée et présente celle qui minimise  $Fs$  (surface critique), fournissant ainsi une évaluation cohérente avec la géométrie décrite et les propriétés des matériaux (Figure 1).

Afin de constituer un volume conséquent de paires entrées/sorties pour l'apprentissage, nous avons fait appel à un mode script dans **Talren** pour automatiser et enchaîner un grand nombre de calculs. Ce mode permet de lire et d'exécuter automatiquement un fichier de calcul **Talren**. Nous avons donc développé un script *Python* générant directement ces scripts **Talren** prêts à être calculés. Cette procédure nous a permis de dérouler l'ensemble des simulations de manière fiable et systématique.

Chaque script paramètre la géométrie du talus ( $H, L, L_1, L_3$ ), les caractéristiques mécaniques du sol ( $\gamma, c, \varphi$ ) et l'éventail des surfaces à explorer via la définition des intervalles d'entrée et de sortie sur les plateaux amont et aval (de longueur  $L$ ) (Figure 2). Le moteur exécute ensuite les simulations et retourne, pour chaque configuration, le facteur de sécurité  $Fs$ , le centre  $(C_x, C_y)$ , le rayon  $R$  du cercle critique ainsi que les points d'intersection de la surface avec l'enveloppe du talus ( $d_{in}, d_{out}$ ), assurant une traçabilité et une reproductibilité complètes des résultats.




Figure 1. Exemple du calcul de stabilité sur Talren v6

## 2.2 Génération du jeu de données

### 2.2.1 Hypothèses et cadre du jeu de données

Nous adoptons un cas très simplifié de talus monocouche (pente unique, sol homogène), excluant surcharges et conditions hydrauliques, avec pour objectif de quantifier la performance de modèles ensemblistes dans l'approximation des calculs **Talren**. Les résultats de référence (méthode de *Bishop*,  $Fs$  minimal et paramètres de la surface critique) constituent les cibles de l'apprentissage supervisé.




Figure 2. Convention des paramètres géométriques

### 2.2.2 Espace paramétrique et distributions de tirage

Pour couvrir un domaine réaliste tout en préservant la diversité, les paramètres d'entrée sont générés selon des lois physiquement plausibles :

Paramètres géométriques :

- Hauteur de talus  $H$ [m] : tirage uniforme sur  $[0 ; 30]$
- Rapport d'élanement  $L/H$  : distribution normale tronquée  $\mu = 1,5$ ,  $\sigma = 0,5$ , bornée sur  $[0,3 ; 3,2]$  (sur-échantillonnage puis troncature pour exclure les talus extrêmes)
- Largeur  $L$ [m] : calculée telle que  $L = \left(\frac{L}{H}\right) \times H$
- Longueurs de plateau amont/aval  $(L_1, L_3)$ [m] : multiples de  $L$  avec un facteur tiré uniformément dans  $[1 ; 4]$ . Ce choix a peu d'influence sur les calculs, car les sols sont horizontaux et, dès lors que  $L_1$  et  $L_3$  sont supérieurs à  $L$ , leur valeur importe peu. Il sert surtout à diversifier le jeu de données.

Paramètres mécaniques du sol :

- Poids volumique  $\gamma$ [kN/m<sup>3</sup>] : distribution normale tronquée  $\mu = 20$ ,  $\sigma = 2,5$ , bornée sur  $[15 ; 25]$
- Angle de frottement interne  $\varphi$ [°] : distribution normale tronquée  $\mu = 25$ ,  $\sigma = 10$ , bornée sur  $[0 ; 45]$
- Cohésion  $c$ [kPa] : mélange d'une distribution exponentielle (facteur d'échelle 10) tronquée sur  $[0 ; 50]$  et d'une distribution uniforme sur  $[0 ; 5]$ , pour mieux représenter les faibles cohésions souvent rencontrées.

Ces choix garantissent une dispersion contrôlée : ils évitent les géométries irréalistes (quasi verticales ou excessivement étalées) et reflètent des plages usuelles de paramètres de sol.

Les distributions des variables générées sont présentées dans la Figure 3.

### 2.2.3 Exécution des calculs et séparation des données

Pour constituer le premier corpus, 9500 configurations ont été générées automatiquement et exécutées via le mode script de **Talren** (1 jour de calcul environ). Sur ce lot initial, les données ont été séparées en trois

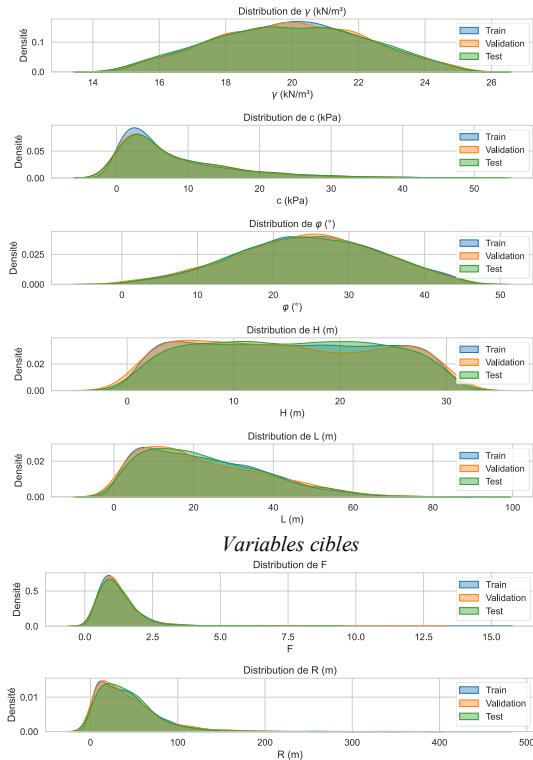


Figure 3. Distribution des variables après séparation des données

sous-ensembles indépendants :

- Entraînement (*train*) : 70 %
- Validation (*val*) : 15 %
- Test (*test*) : 15 %

La séparation est réalisée de façon purement aléatoire. Une vérification a posteriori a confirmé que les distributions des variables d'intérêt restent comparables entre les trois sous-ensembles, garantissant l'absence de déséquilibre induit par le découpage (Figure 3). Pour garantir la reproductibilité, les graines aléatoires ont été fixées et les index de séparation conservés. Le jeu de test a été mis sous embargo et strictement réservé à l'évaluation finale ; il n'a jamais été utilisé pour le calage des hyperparamètres, la sélection de modèles, l'ingénierie des variables ou les analyses intermédiaires, afin d'éviter toute fuite de données ou biais de mesure de performance.

#### 2.2.4 Enrichissements de données *Data-Driven*

L'analyse descriptive des données d'entraînement a mis en évidence deux déséquilibres statistiques dans les paramètres de la surface critique : une sous-représentation- des grands rayons ( $R > 60$  m) et une forte concentration de la distance de sortie  $d_{out}$  autour de zéro. Ces déséquilibres peuvent induire un apprentissage biaisé, réduisant la capacité du modèle à prédire correctement des configurations rares mais critiques, c'est pourquoi nous avons réalisé un enrichissement

des données afin de rééquilibrer l'espace des paramètres et d'améliorer la généralisation.

Pour corriger ces biais sans compromettre le réalisme, nous avons procédé à un enrichissement ciblé : d'une part, plus de sept mille nouvelles configurations orientées vers les grands rayons, guidées par une analyse statistique des zones de paramètres et filtrées au moyen d'un classificateur sélectionnant les combinaisons susceptibles d'induire des  $R$  élevés ; d'autre part, cinq milles configurations supplémentaires visant à diversifier la distribution de  $d_{out}$  et à réduire le pic en zéro.

Afin d'éviter une sur-spécialisation du corpus, nous avons conservé environ 10 % des configurations initialement écartées par le classificateur (c'est-à-dire celles prédites comme peu susceptibles d'induire des valeurs élevées de  $R$ ) de manière à maintenir une diversité contrôlée. Au total, les données d'entraînement consolidé approchent 20 000 configurations valides, offrant une couverture élargie des géométries et des propriétés mécaniques, mieux adaptée à l'apprentissage des modèles ensemblistes.

### 3 DEFINITION DES SCENARIOS POUR L'APPRENTISSAGE

#### 3.1 Paramètres cibles

Les scénarios d'apprentissage ont été formulés en régression supervisée à partir des sorties de référence **Talren**, avec deux objectifs complémentaires :

- Prédire le facteur de sécurité  $F_s$  critique,
- Approximer la géométrie de la surface.

Dans l'approche initiale, comme indiqué précédemment, la géométrie a été exprimée par les coordonnées du centre ( $C_x, C_y$ ) et le rayon  $R$ . Cette représentation s'est avérée difficile à apprendre en raison de sa forte sensibilité aux petites variations issues des calculs Talren : plusieurs surfaces légèrement différentes peuvent conduire à des centres très éloignés alors que leurs facteurs de sécurité sont quasi identiques. Nous l'avons donc reformulée en ciblant  $R$ ,  $d_{in}$  et  $d_{out}$ , paramètres mieux bornés par la géométrie du talus et plus stables pour l'apprentissage.

#### 3.2 Paramètres explicatifs

Les modèles apprennent à partir des variables d'entrée directement issues de la description du talus et du sol :

- Géométrie : hauteur  $H$ , largeur  $L$ , longueurs ( $L_1, L_3$ ).
- Mécanique du sol : poids volumique  $\gamma$ , cohésion  $c$ , angle de frottement interne  $\phi$ .

Ces variables couvrent l'information minimale nécessaire pour relier la configuration (géométrique et mécanique) aux sorties de référence **Talren** ( $F_s$ , géométrie de rupture).

Bien que ces variables décrivent l'information minimale nécessaire pour relier la configuration du talus aux paramètres cibles, leur utilisation directe peut ne pas suffire à capturer les interactions non linéaires et les relations physiques complexes entre paramètres. Un travail d'ingénierie des données (*feature engineering*) a donc été mené afin de construire des variables dérivées plus représentatives des mécanismes de stabilité, facilitant l'apprentissage du modèle et améliorant sa capacité de généralisation.

### 3.2.1 Variables dérivées

Afin de faciliter l'apprentissage des relations non linéaires par les algorithmes ensemblistes, des caractéristiques dérivées à sens physique ont été ajoutées :

- Rapport d'élanement :  $L/H$
- Pente :  $\arctan\left(\frac{H}{L}\right)$
- Valeur de la pente du talus en degrés
- Projection de l'angle de frottement :  $\tan(\varphi)$
- Ratios sur la cohésion :  $\frac{c}{\gamma \cdot H}$  et  $\frac{c}{L}$
- Échelle géométrique :  $A = H \cdot L$
- Couplage géométrie-frottement :  $L \cdot \tan(\varphi)$

Ces transformations mettent l'accent sur des rapports et couplages connus en géotechnique (effets d'échelle, compromis cohésion/poids propre, rôle du frottement). Elles réduisent l'effort de découverte que doit fournir l'algorithme et améliorent la stabilité des prédicteurs.

### 3.2.2 Combinaisons polynomiales (degré 2)

Pour capturer les interactions de premier et de second ordre entre facteurs, nous avons généré des combinaisons polynomiales de degré 2 à partir des variables brutes et dérivées ci-dessus. Exemples (non exhaustifs, conformes aux combinaisons retenues dans l'étude) :

- Interactions de 1<sup>er</sup> ordre avec  $H$ :  $H \cdot L$ ,  $H \cdot \varphi$ ,  $H \cdot \tan(\varphi)$ ,  $\tan(\varphi) \cdot \frac{c}{\gamma \cdot H}$ ,  $H \cdot \frac{c}{L}$ ,  $H \cdot A$
- Combinaisons mécaniques :  $c \cdot \frac{c}{\gamma \cdot H}$ ,  $c \cdot \frac{c}{L}$ ,  $\frac{c}{\gamma \cdot H} \cdot \frac{c}{L}$ ,  $\frac{c}{\gamma \cdot H} \cdot A$

### 3.2.3 Sélection des combinaisons (procédure et variables finales)

Bien que la génération de combinaisons permette d'enrichir l'espace des caractéristiques, elle conduit à un nombre élevé de variables potentiellement redondantes et fortement corrélées, ce qui accroît la complexité du modèle, favorise le sur-apprentissage et rend la phase de calibration particulièrement délicate.

En particulier, conserver l'ensemble des combinaisons complique l'identification d'un jeu d'hyperparamètres optimal et stable.

Afin de maîtriser cette complexité et de préserver les capacités de généralisation, une sélection des variables a été réalisée en appliquant une technique de criblage par modèle basée sur *XGBoost* (Chen & Guestrin, 2016).

Le modèle *XGBoost Regressor* est entraîné cible par cible afin d'estimer l'importance des variables. La procédure de sélection a été prioritairement appliquée à la prédiction du paramètre le plus complexe à estimer, à savoir le rayon  $R$ , dont la variabilité et la sensibilité aux paramètres d'entrée sont les plus élevées. Les caractéristiques ont ensuite été classées et retenues selon leur contribution à la performance en validation croisée. Le sous-ensemble parcimonieux obtenu concentre l'information la plus discriminante et stabilise l'apprentissage. Ce même jeu de variables sélectionnées pour  $R$  a ensuite été utilisé pour les autres cibles, pour lesquelles il s'est également avéré performant, assurant ainsi une cohérence et une efficacité globale du processus de modélisation.

En définitive, 28 variables les plus pertinentes issues du criblage sont retenues comme socle commun pour  $R$ ,  $d_{in}$  et  $d_{out}$ . Lorsque l'information du rayon  $R$  améliore une autre cible, elle est injectée sous forme d'une prédiction *out-of-fold* (Naimi, A. I., et al. (2018).) afin d'éviter toute fuite de données.

Pour le facteur de sécurité  $F_s$ , les performances du modèle étant bien stables, nous avons pu éliminer plusieurs combinaisons sans perte de précision. Après filtrage, seules les variables suivantes ont été conservées :  $\gamma$ ,  $c$ ,  $\varphi$ ,  $H$ ,  $\tan(\varphi)$ ,  $\frac{c}{L}$ ,  $\frac{c}{\gamma \cdot H}$ , Pente,  $L$ ,  $\varphi$

## 3.3 Choix des modèles et métriques

### 3.3.1 Définition des métriques pour chaque paramètre

L'évaluation des performances des modèles repose sur plusieurs indicateurs quantitatifs couramment utilisés en régression, permettant d'apprécier la précision et la robustesse des prédictions par rapport aux valeurs de référence issues de **Talren**. Les métriques retenues sont :

- MSE (*Mean Squared Error*), MAE (*Mean Absolute Error*), RMSE (*Root Mean Squared Error*) MAPE (*Mean Absolute Percentage Error*) : valeurs recherchées les plus petites possible.
- $R^2$  (Coefficient de détermination) : valeur recherchée la plus proche de 1.

L'utilisation conjointe de ces métriques offre une évaluation complète et équilibrée : la MAE renseigne sur

la précision moyenne, la RMSE sur la stabilité des prédictions, la MSE sur la sensibilité aux grandes erreurs, la MAPE sur la qualité relative des estimations, et le  $R^2$  sur la fidélité globale du modèle par rapport au comportement du calcul de référence. Ces indicateurs serviront de base à la comparaison entre les différents modèles testés et aux ajustements successifs réalisés lors de l'affinage des hyperparamètres.

### 3.3.2 Choix des modèles

Après une phase comparative initiale impliquant différents modèles (régression linéaire, arbres de décision, réseaux de neurones simples et profonds), trois algorithmes se sont distingués par leurs performances et leur stabilité dans les prédictions du facteur de sécurité et les paramètres de la surfaces critique : *XGBoost* (*Extreme Gradient Boosting*), *LightGBM* (*Light Gradient Boosting Machine*) et *ExtraTrees Regressor* (*Extremely Randomized Trees*).

Ces modèles présentent des atouts majeurs pour cette étude : ils permettent de capturer efficacement les relations non linéaires complexes entre les paramètres géométriques et mécaniques du talus, offrent une robustesse accrue face aux valeurs extrêmes et aux distributions non uniformes, requièrent un prétraitement minimal des données (sans normalisation stricte ni transformation), et intègrent des mécanismes de régularisation limitant les risques de surapprentissage.

## 4 RESULTATS DE L'APPRENTISSAGE

Après plusieurs itérations d'apprentissage et d'enrichissement progressif des données, nous avons procédé à une recherche des hyperparamètres pour chaque modèle en utilisant la validation croisée sur l'ensemble d'entraînement (Bergstra & Bengio, 2012). Cette étape a permis d'identifier les configurations optimales en fonction des métriques prédéfinies. Le modèle retenu pour chaque paramètre est celui qui a présenté les meilleures performances moyennes, assurant ainsi une capacité de généralisation satisfaisante.

### 4.1 Prédiction du facteur de sécurité

Bien que les deux modèles *XGBoost* et *ExtraTreesRegressor* aient montré des performances très proches et élevées pour la prédiction du  $F_s$ , nous avons retenu *XGBoost* principalement pour sa robustesse et la facilité d'interprétation offerte par l'approche SHAP (*SHapley Additive exPlanations*), essentielle pour analyser les relations entre les variables d'entrée et le facteur de sécurité.

Tableau 1. Indicateurs de performance du modèle pour la

prédiction de  $F_s$  sur les deux ensembles (validation et test)

Dataset	Val (F)	Test (F)
MAE	0,0271	0,026
MSE	0,002	0,002
RMSE	0,048	0,050
MAPE	2,38%	2,40%
$R^2$	0,997	0,996

Le Tableau 1 et la Figure 4 présentent les performances du modèle évaluées sur les ensembles de validation et de test. Les résultats montrent des erreurs faibles sur l'ensemble des métriques considérées, avec une MAE et une RMSE particulièrement réduites, indiquant une bonne précision globale des prédictions. Les valeurs de MAPE inférieures à 3 % traduisent une erreur relative limitée, confirmant la capacité du modèle à reproduire fidèlement les tendances des données.




Figure 4. Évaluation de la prédiction des facteurs de sécurité avec une bande de tolérance  $\pm 0,25$

Les scores test, légèrement supérieurs à la validation, relèvent probablement de l'aléa d'échantillonnage.

On observe par ailleurs des performances légèrement meilleures sur le jeu de test que sur le jeu de validation, ce qui suggère une bonne capacité de généralisation du modèle et l'absence de surapprentissage. Cette observation est corroborée par les coefficients de détermination élevés ( $R^2 > 0,99$ ) sur les deux ensembles, indiquant que le modèle explique la quasi-totalité de la variance des données.

Néanmoins, afin de confirmer la robustesse de ces performances et de s'affranchir d'un éventuel biais lié à une partition particulière des données, une validation croisée a été mise en œuvre.

#### 4.1.1 Validation croisée

La performance du modèle est évaluée à l'aide d'une validation croisée *k-fold* avec  $k = 5$ , une approche classique pour estimer la stabilité et la capacité de généralisation d'un modèle (Kohavi, 1995). Les performances obtenues sur chaque *fold* (pli), présentées dans le Tableau 2, montrent une grande cohérence entre les différents sous-ensembles de données.

Tableau 2. Évaluation des prédictions du  $F_s$  par validation croisée (5 folds)

Fold	1	2	3	4	5
MAE	0,027	0,027	0,027	0,026	0,027
MSE	0,004	0,003	0,005	0,004	0,006
RMSE	0,069	0,062	0,073	0,067	0,082
MAPE	2,87%	3,07%	2,80%	2,78%	2,54%
$R^2$	0,993	0,995	0,995	0,994	0,991

Le coefficient de détermination moyen atteint  $R^2 = 0,9937 \pm 0,0013$ , indiquant que plus de 99 % de la variance de la variable cible est expliquée par le modèle. Les erreurs moyennes restent très faibles (MAE  $\approx 0,0270$ , RMSE  $\approx 0,0709$ , MAPE  $\approx 2,8141$  %), avec une variabilité limitée d'un fold à l'autre. Cette faible dispersion des métriques témoigne d'une excellente robustesse du modèle et d'une bonne généralisation sur différents sous-échantillons des données, confirmant ainsi la fiabilité des performances observées lors des évaluations sur les ensembles de validation et de test.

#### 4.1.2 Courbes d'apprentissages

Les courbes d'apprentissages permettent d'observer comment les performances d'un modèle évoluent durant son entraînement. Elles offrent une vision rapide de sa capacité à apprendre, à se stabiliser et à généraliser, tout en aidant à détecter d'éventuels problèmes de sous-apprentissage ou de surapprentissage.

La Figure 5 présentent l'évolution du RMSE au fil des itérations de *boosting*, permettant d'observer la dynamique d'apprentissage du modèle et la convergence des erreurs d'entraînement et de validation.




Figure 5. Courbes d'apprentissages du modèle pour la prédiction du facteur de sécurité

Ce graphique montre une chute rapide et conjointe des erreurs *Train* et *Validation* entre 0 et 200 itérations (d'environ 0,9 vers 0,1), puis une décroissance plus lente jusqu'à  $\sim 1500$  itérations. L'écart généralisation (*Train* vs *Validation*) reste faible sur toute la trajectoire et demeure de l'ordre de 0,001-0,002 en fin d'entraînement ( $\text{Train} \approx 0,034$  et  $\text{Validation} \approx 0,051$ ), ce

qui suggère une bonne capacité de généralisation et pas de surapprentissage marqué. À partir d'environ 300-400 itérations, les gains deviennent marginaux : la validation ne s'améliore plus que très progressivement. Cela suggère que l'activation un *early stopping* autour de ce palier, ou une réduction du nombre d'arbres, pourrait diminuer le temps d'entraînement sans perte notable de performance.

#### 4.1.3 Importance des variables

Le graphique SHAP (Figure 6) illustre à la fois l'importance globale et l'influence locale de chaque variable sur la prédiction de  $F_s$ .

Les variables sont ordonnées selon leur importance moyenne dans le modèle, de la plus influente en haut à la moins contributive en bas. Chaque point correspond à une observation et sa position horizontale indique l'impact de la variable sur la prédiction, positif ou négatif. Les valeurs SHAP positives traduisent une augmentation de  $F_s$ , tandis que les valeurs négatives indiquent une diminution. La couleur encode la valeur de la variable (bleu : faible, rouge : élevée), permettant d'identifier le sens de l'influence. Par exemple, pour la variable *Pente*, les points rouges (valeurs élevées) se concentrent majoritairement du côté négatif des valeurs SHAP, indiquant qu'une pente élevée contribue à une diminution du facteur de sécurité  $F_s$ . À l'inverse, les points bleus (faibles valeurs de pente) sont associés à des valeurs SHAP positives, traduisant une augmentation du facteur de sécurité lorsque la pente est faible.




Figure 6. Analyse SHAP des variables explicatives pour le facteur de sécurité

#### 4.2 Prédiction de la surface critique

La prédiction de la surface critique reste néanmoins un exercice plus complexe que celle du facteur de sécurité, les variables géométriques présentant une dispersion naturelle plus importante et une structure moins régulière. Dans ce cadre, ExtraTrees Regressor s'est montré plus performant que XGBoost : sa nature fortement aléatoire et sa moindre sensibilité aux fluctuations des données lui permettent de mieux capturer les relations non linéaires entre paramètres géométriques et mécaniques. Les résultats obtenus avec cet

algorithmes sont sensiblement meilleurs, offrant une précision accrue sur l'ensemble des prédictions géométriques.

#### 4.2.1 Prédiction du rayon

La Figure 7 montre une forte corrélation entre les valeurs prédites et les valeurs réelles, aussi bien pour le jeu de validation que pour le jeu de test. Les points sont étroitement alignés le long de la diagonale, ce qui traduit une excellente fidélité du modèle aux résultats issus du calcul **Talren**, y compris pour les grands rayons.




Figure 7. Évaluation de la prédiction des rayons  $R[m]$  avec bande de tolérance  $\pm 10$  m

Les écarts les plus notables apparaissent principalement pour les rayons supérieurs à 250 m, zone où les valeurs sont plus rares et la variabilité géométrique plus importante. Cependant, ces écarts ne remettent pas en cause la robustesse globale du modèle, qui conserve une cohérence remarquable sur l'ensemble des configurations simulées. Les indicateurs statistiques de l'erreur (Tableau 3) confirment ces observations :

- Le modèle affiche un coefficient de détermination supérieur à 0,97, traduisant une très bonne qualité d'ajustement, et des erreurs absolues faibles (MAE  $\approx 2$  m) sur l'ensemble de validation comme de test.
- Les erreurs quadratiques (RMSE  $\approx 4$  à 6 m) restent limitées au regard de l'échelle des rayons étudiés, et le MAPE inférieur à 6 % démontre une bonne stabilité relative sur l'ensemble du domaine de valeurs.

Tableau 3. Indicateurs de performance du modèle pour la prédiction de  $R[m]$  sur les deux ensembles

Dataset	Val ( $R$ )	Test ( $R$ )
MAE	2,011	2,364
MSE	18,730	37,644
RMSE	4,328	6,135
MAPE	5,61%	5,68%
$R^2$	0,987	0,975

#### 4.2.2 Prédiction des distances d'entrée et de sortie

Les distances d'entrée ( $d_{in}$ ) et de sortie ( $d_{out}$ ) représentent des paramètres essentiels pour la reconstitution complète de la surface critique. Leur bonne estimation

conditionne directement la cohérence géométrique du cercle de rupture et la position de la surface dans le massif. Les modèles dédiés à ces deux variables ont été entraînés à partir du dataset enrichi, utilisant les mêmes paramètres explicatifs que pour la prédiction du facteur de sécurité.

#### 4.2.3 Prédiction de la distance d'entrée

Les résultats obtenus pour la variable  $d_{in}$  (Figure 8) montrent une corrélation globalement satisfaisante entre les valeurs prédites et celles calculées par **Talren**.




Figure 8. Évaluation de la prédiction des distances d'entrées  $d_{in}[m]$  avec bande de tolérance  $\pm 1$  m

Bien que les points présentent une légère dispersion autour de la diagonale, la tendance générale reste correctement reproduite. Les indicateurs de performance confirment la bonne capacité du modèle à estimer la position d'entrée de la surface critique, avec un  $R^2$  supérieur à 0,97 et des erreurs moyennes très faibles (MAE  $\approx 0,23$  m).

Tableau 4. Indicateurs de performance du modèle pour la prédiction de la distance d'entrée

Dataset	Val ( $d_{in}$ )	Test ( $d_{in}$ )
MAE	0,228	0,230
MSE	0,115	0,114
RMSE	0,339	0,337
$R^2$	0,973	0,970

#### 4.2.4 Prédiction de la distance de sortie

La variable  $d_{out}$  présente une forte concentration de valeurs nulles, ce qui rend sa prédiction plus difficile.




Figure 9. Évaluation de la prédiction des distances d'entrées  $d_{out}[m]$  avec bande de tolérance  $\pm 1$  m

Malgré cela, le modèle parvient à bien reproduire la

tendance générale, avec un  $R^2$  supérieur à 0,97 sur les deux ensembles et des erreurs très faibles ( $MAE < 0,02$  m).

Tableau 5. Indicateurs de performance du modèle pour la prédiction de la distance de sortie

Dataset	Val ( $d_{out}$ )	Test ( $d_{out}$ )
MAE	0,016	0,009
MSE	0,011	0,003
RMSE	0,104	0,055
$R^2$	0,978	0,981

#### 4.2.5 Comparaison entre le modèle et Talren

Bien que les paramètres géométriques  $R$ ,  $d_{in}$  et  $d_{out}$  aient été prédits séparément, sans aucune contrainte géométrique imposée entre eux, les résultats montrent une cohérence remarquable. Sur l'ensemble des  $2 \times 1437$  configurations de test et de validation, une seule surface non valide a été identifiée, correspondant à un cas où le rayon prédit ne satisfait pas la condition géométrique  $R < (E - S)/2$ , rendant la surface de rupture impossible.

Afin d'évaluer la cohérence géométrique des surfaces prédites, nous avons défini une mesure d'écart surfacique entre la surface calculée par **Talren** et celle reconstruite à partir des prédictions du métamodèle ( $R$ ,  $d_{in}$ ,  $d_{out}$ ). Les descriptions des écarts surfaciques sont présentées dans le Tableau 6.

Avec une moyenne d'environ 4,3 m<sup>2</sup> et une médiane de 1,66 m<sup>2</sup>, rapportée à une double surface moyenne de talus de l'ordre de 224 m<sup>2</sup> ( $H * L$ ), l'erreur relative reste modérée. Cela indique que les surfaces critiques prédites sont géométriquement cohérentes avec celles calculées par **Talren**, même sans contrainte directe entre les paramètres prédits.

L'analyse approfondie des erreurs montrent que les plus grands écarts surviennent principalement pour des géométries particulières, souvent associées à des rayons très élevés et/ou des géométries assez grandes : dans ces configurations, une faible variation du rayon ou des points d'intersection peut produire une différence surfacique importante, sans pour autant compromettre la cohérence géométrique globale de la surface.

Dans l'ensemble, même pour ces cas extrêmes, la forme générale et la localisation de la surface critique restent réalistes, traduisant la robustesse du métamodèle.

Tableau 6. Écart surfacique entre les arcs prédits et les arcs calculés par Talren

Dataset	Val (F)	Test (F)
Moyenne	4,34	4,38
Std	10,67	7,01
25%	0,5	0,57
50%	1,66	1,92

75%	4,70	5,15
Max	238,79	66,34

## 5 CONCLUSIONS

Les résultats obtenus au cours de cette étude confirment la capacité du métamodèle à prédire avec une grande précision le facteur de sécurité ( $F_s$ ), avec des performances quasi parfaites. La principale difficulté rencontrée durant ce travail réside dans l'approximation de la surface critique, une tâche particulièrement complexe. Cette complexité tient à la forte variabilité des données géométriques : de faibles différences entre les surfaces donnent des  $F_s$  quasiment identiques, ce qui réduit le pouvoir discriminant des variables.

Des essais préliminaires ont montré que les prédictions du  $F_s$  restaient excellentes même pour des talus présentant des inclinaisons avant et après le talus principal ; toutefois, pour simplifier le problème, l'étude s'est limitée aux talus sans inclinaison. Globalement, l'approche consistant à enrichir le jeu de données s'est révélée très efficace pour améliorer la qualité des prédictions. En revanche, une complexification excessive du modèle rendrait difficile la couverture de tous les cas possibles.

L'objectif est maintenant d'exploiter ce métamodèle dans un outil de prévision préliminaire intégré à la plateforme **Orbow** afin d'en évaluer la pertinence pour les études. Nous prévoyons ensuite d'enrichir progressivement ce modèle de cas d'usages courant (plusieurs sols, nappe, charges en tête, risberme, renforcements, etc.).

## 6 REFERENCES BIBLIOGRAPHIQUES

- Notice technique du logiciel Talren : <https://terra-sol.setec.fr/logiciels/talren>
- Wegmeth, D., et al. (2023). *The Effect of Random Seeds for Data Splitting on Machine Learning Results*. CEUR Workshop Proceedings, Vol-3476
- Naimi, A. I., et al. (2018). *Stacked Generalization: An Introduction to Super Learning*
- Chen, T., & Guestrin, C. (2016). *XGBoost: A scalable tree boosting system*. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 785–794
- Bergstra, J., & Bengio, Y. (2012). *Random Search for Hyper-Parameter Optimization*. Journal of Machine Learning Research, 13, 281–305
- Kohavi, R (1995), *A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection*, Computer Science Department Stanford University