

Gestion du risque « cavités » : Apports de l'IA et des Modèles Prédictifs

Risk Management for Underground Cavities: Contributions of AI and Predictive Models

Nathalie CONIL^{1*}, Lina Maria GUAYACAN CARRILLO², Jean-Bernard KAZMIERCZAK¹, Loïc MASUY¹,
Amélie LECOMTE¹

1 Institut National de l'Environnement Industriel et des Risques, Verneuil-en-Halatte, France

**nathalie.conil@ineris.fr*

RESUME : L'Ineris a récemment développé une approche innovante combinant apprentissage automatique et expertise géotechnique pour l'étude des phénomènes d'effondrement des carrières souterraines abandonnées. Cette démarche repose sur l'exploitation de bases de données issues de mesures in situ et de retours d'expérience, incluant notamment des effondrements historiques. Les différentes étapes sont rigoureusement structurées, depuis le prétraitement et la validation des données jusqu'à l'entraînement et le déploiement des modèles. Plusieurs méthodes d'apprentissage ont été explorées, avec des approches ensemblistes montrant des performances prometteuses pour ces premiers travaux. Un défi majeur identifié concerne la qualité et la quantité limitées des données disponibles. L'usage de données synthétiques complémentaires permet d'améliorer partiellement la performance des modèles, mais ne suffit pas encore à garantir des prédictions robustes. Pour répondre à cette limitation, un système de type Retrieval-Augmented Generation (RAG) a été mis en place afin d'enrichir automatiquement les bases de données à partir de documents techniques. Les résultats initiaux sont encourageants, bien que certaines optimisations restent nécessaires pour un déploiement opérationnel efficace. L'objectif final est de produire des outils prédictifs directement exploitables par les ingénieurs. Cette approche illustre la complémentarité entre intelligence artificielle et expertise humaine pour améliorer la compréhension des mécanismes d'effondrement et la gestion des risques associés aux carrières souterraines abandonnées.

ABSTRACT: Ineris has recently developed an innovative approach combining machine learning and geotechnical expertise to investigate collapse phenomena in abandoned underground quarries. This methodology is based on the exploitation of databases derived from in situ measurements and field feedback, notably including historical collapse events. The workflow is rigorously structured, encompassing data preprocessing and validation through to model training and deployment. Several learning methods were explored, with ensemble learning approaches showing promising performance in these initial studies. A major challenge identified concerns the limited quality and quantity of available data. While the use of complementary synthetic data partially enhances model performance, it remains insufficient to guarantee robust predictions. To address this limitation, a Retrieval-Augmented Generation (RAG) system was implemented to automatically enrich the databases using technical documentation. Initial results are encouraging, although further optimizations are required for effective operational deployment. The ultimate objective is to develop predictive tools that are directly usable by engineers. This approach illustrates the synergy between artificial intelligence and human expertise in improving the understanding of collapse mechanisms and the management of risks associated with abandoned underground quarries.

Mots-clés : Carrières souterraines abandonnées ; Apprentissage automatique (machine learning) ; Effondrements ; Outils prédictifs, RAG.

1 INTRODUCTION

La France compte plusieurs dizaines de milliers de carrières souterraines abandonnées, souvent peu profondes et laissées sans entretien depuis plusieurs décennies. Si elles constituent un patrimoine géologique important, elles représentent également un risque pour la sécurité publique en raison des effondrements qu'elles sont susceptibles d'engendrer en surface. L'évaluation de leur stabilité est complexe, car elle résulte de l'interaction de nombreux

paramètres mécaniques, hydrogéologiques et environnementaux.

Si les facteurs de prédisposition des effondrements sont relativement bien identifiés, le rôle des facteurs aggravants ou déclenchant, en particulier climatiques, demeure encore mal quantifié. Or, l'intensification attendue des événements climatiques extrêmes, tels que les fortes précipitations ou les périodes de sécheresse prolongée, est susceptible d'affecter le comportement hydromécanique des roches et la stabilité des carrières, notamment dans des formations sensibles à l'eau comme la craie.

Dans ce contexte, l’Ineris a engagé depuis plusieurs années un programme de recherche visant à analyser les liens entre variations climatiques, facteurs internes et externes et stabilité des carrières souterraines. Ce programme s’appuie sur des bases de données d’effondrements passés, des études de cas, des essais expérimentaux, des modélisations numériques et des dispositifs d’observation in situ. En parallèle, de nouvelles approches d’intelligence artificielle ont été développées, combinant apprentissage automatique et architectures de type *Retrieval-Augmented Generation* (RAG) afin d’enrichir et d’exploiter les données disponibles.

L’objectif est de croiser puissance de calcul et expertise géotechnique pour mieux comprendre les mécanismes d’effondrement et développer des outils prédictifs fiables et interprétables. Cet article présente cette démarche et son application à l’inventaire des effondrements créé par l’Ineris (Conil et Gombert 2024), dans la perspective d’une amélioration durable de l’évaluation et de la gestion des risques liés aux carrières souterraines abandonnées dans un contexte de changement climatique.

2 CONTEXTE

2.1 Typologie des effondrements dans les carrières ou mines souterraines

Dans le domaine des cavités souterraines, la typologie des instabilités est aujourd’hui bien établie grâce aux nombreux retours d’expérience et aux travaux menés par la communauté scientifique et technique (Tritsch et al. 2007, Bennani et al. 2016). Trois grandes catégories de mouvements de terrain sont généralement distinguées : les effondrements localisés, les affaissements et les effondrements généralisés. Les effondrements localisés résultent le plus souvent de la dégradation ponctuelle d’une partie du toit de la cavité ou de la rupture d’un pilier. Les affaissements correspondent à une déformation lente et progressive du massif, pouvant évoluer sans rupture brutale mais entraînant des mouvements différentiels significatifs. Enfin, les effondrements généralisés impliquent la défaillance simultanée ou en cascade d’un ensemble de piliers, provoquant l’effondrement d’un niveau complet de galeries et la création de dépressions de grande amplitude en surface.

Cette diversité morphologique traduit la variété des configurations et des architectures propres aux carrières, des conditions hydrogéologiques et des mécanismes de déformation à l’œuvre dans les carrières souterraines abandonnées.

2.2 Facteurs favorisant les effondrements

Les effondrements, qu’ils affectent ponctuellement une zone limitée ou qu’ils concernent la quasi-totalité d’une carrière souterraine, résultent de la combinaison de plusieurs facteurs interdépendants (Conil et Gombert 2024; Al Heib et al. 2023). Ces facteurs peuvent être regroupés en deux grandes catégories. Les facteurs de prédisposition relèvent des caractéristiques intrinsèques de la cavité : géométrie des galeries, taux de défrêtement, nature lithologique du matériau exploité ou encore caractéristiques du recouvrement, qu’il s’agisse de sa composition ou de son épaisseur. À ceux-ci s’ajoutent les facteurs aggravants et/ou déclenchants, liés à des éléments externes susceptibles de perturber l’équilibre du massif, tels que la géomorphologie locale, la présence de failles ou d’hétérogénéités, l’infiltration d’eau, les événements climatiques, ou d’autres sollicitations naturelles ou anthropiques.

Si le rôle de l’eau dans la dégradation des carrières souterraines est largement reconnu, le retour d’expérience montre que peu d’effondrements peuvent être directement attribués à des événements climatiques isolés. Le manque de recul temporel et la superposition d’effets lents compliquent l’évaluation, certains impacts pouvant se manifester longtemps après l’événement initial. Néanmoins, plusieurs effondrements coïncident avec des épisodes climatiques extrêmes (Conil et Gombert, 2024), ce qui suggère une possible contribution du climat, même si celle-ci reste difficile à dissocier des autres facteurs impliqués.

2.3 État de l’art

L’analyse de la stabilité des carrières souterraines repose classiquement sur l’étude des propriétés géotechniques et géomécaniques du massif ainsi que sur des modélisations numériques des mécanismes de rupture. Toutefois, la complexité des comportements hydromécaniques et la rareté des données disponibles rendent difficile l’établissement de relations explicites entre variables, en particulier dans le cas de bases de données hétérogènes et incomplètes.

Dans ce contexte, les méthodes d’apprentissage automatique (machine learning, ML) suscitent un intérêt croissant en raison de leur capacité à traiter des systèmes non linéaires. Leur efficacité reste néanmoins fortement conditionnée par la quantité et la qualité des données, les jeux de données restreints exposant les modèles à des risques de surapprentissage. Pour répondre à ces limites, plusieurs travaux ont proposé des approches hybrides combinant modélisation numérique et ML, notamment via des approches de type *physics-informed*,

combinant données et connaissances physiques, ou la génération de données synthétiques à partir de simulations numériques (Tristani et al. 2025).

Par ailleurs, les approches ensemblistes se sont révélées particulièrement adaptées aux problématiques géotechniques et liées aux carrières disposant de données contraintes, en améliorant la robustesse et la stabilité des prédictions (Guayacán-Carrillo et al. 2025 ; Richa et al. 2025). Enfin, l'interprétabilité des modèles constitue un enjeu majeur pour une utilisation opérationnelle en gestion du risque, des méthodes telles que la régression symbolique permettant d'extraire automatiquement des relations mathématiques explicites directement exploitables par les ingénieurs (Guayacán-Carrillo et Sulem 2024).

C'est dans cette dynamique que s'inscrit le projet mené à l'Ineris. De nombreuses études ont en effet mis en évidence le potentiel des méthodes d'apprentissage automatique pour l'analyse de données géotechniques. Ainsi, Drif et al. (2025) ont montré que l'apprentissage automatique permet de détecter efficacement des chutes de blocs à partir de signaux acoustiques enregistrés dans une carrière de craie abandonnée. En s'appuyant sur des données acquises dans la carrière Royer à Château-Landon (Conil et al. 2023), plusieurs modèles de classification ont été évalués à l'issue d'un traitement approfondi des données, comprenant le prétraitement, l'extraction de caractéristiques, l'augmentation du jeu de données et l'optimisation des hyperparamètres. Après augmentation du jeu de données, les résultats obtenus présentent une précision globale supérieure à 92 %, avec une capacité de détection des chutes de blocs particulièrement élevée (rappel proche de 0,98). Ces travaux démontrent le potentiel des systèmes basés sur l'intelligence artificielle pour améliorer la surveillance et la sécurité des carrières en temps réel, tout en réduisant les besoins en analyses manuelles, et suggèrent une possible généralisation de l'approche à d'autres sites présentant des contextes géologiques variés.

Une démarche similaire a été appliquée à un large corpus de données relatif aux effondrements de carrières souterraines abandonnées (Conil et Gombert 2024), afin d'évaluer la possibilité d'estimer le diamètre des effondrements en surface à partir de variables explicatives complémentaires. Une méthodologie rigoureuse a été mise en œuvre : un nettoyage approfondi des données a d'abord été réalisé, suivi d'analyses statistiques visant à identifier et conserver les paramètres les plus influents.

Des modèles d'apprentissage automatique adaptés ont ensuite été mis en œuvre, en combinaison avec des méthodes d'imputation des données manquantes et de génération de données synthétiques. Les différentes étapes de l'étude sont présentées dans la suite de

l'article, en mettant en évidence les apports et les limites des méthodes d'apprentissage automatique considérées.

3 BASES DE DONNÉES ET STRUCTURATION DE L'INFORMATION

3.1 Description de l'inventaire des effondrements

L'inventaire des effondrements comprend aujourd'hui environ 550 effondrements survenus à l'aplomb de carrières souterraines abandonnées exploitées par la méthode des chambres et piliers abandonnés. Les matériaux d'exploitation retenus à ce stade sont la craie, le gypse et le calcaire en raison de leur sensibilité à l'eau.

Chaque effondrement est idéalement décrit par 48 paramètres, regroupés en quatre classes : la localisation de l'effondrement, l'environnement de la carrière, les caractéristiques de l'exploitation et celles de l'effondrement.

Les paramètres retenus découlent des réflexions et analyses préliminaires réalisées sur l'inventaire.

3.2 Qualité du jeu de données

À ce jour, l'inventaire des effondrements recense environ 150 communes réparties dans 24 départements. Les régions les plus représentées sont la Gironde (calcaire), l'Indre-et-Loire (craie) et l'Île-de-France (gypse), en raison de la présence de services des carrières locaux actifs (EPRCF33, services carrières de la Gironde, Syndicat Cavités 37, IGC de Paris et de Versailles), assurant un recensement plus complet.

Néanmoins, cet inventaire reste non exhaustif : certains effondrements, notamment les plus anciens, peuvent ne pas être recensés, et de nombreux événements survenus dans d'autres départements ne figurent pas dans les bases actuellement disponibles.

Pour chaque paramètre, le taux de renseignement est variable, mais il peut être très faible pour certains d'entre eux, comme la hauteur des galeries où il n'est que de 23 %.

3.3 Préparation des données

3.3.1 Variables d'entrée

Une analyse détaillée de l'inventaire des effondrements a été réalisée afin de constituer un jeu de données exploitable pour la modélisation de l'ampleur des effondrements. Seuls les effondrements

dont le diamètre en surface est supérieur à 5 m ont été conservés, ce qui aboutit à un total de 143 cas exploitables. Le diamètre n'étant pas systématiquement connu. Les variables quantitatives ont été normalisées et les incohérences corrigées.

La sélection des variables a combiné des critères de pertinence et de taux de renseignement. Onze variables initiales ont été retenues, incluant la profondeur maximale, le taux de défrèvement, la distance au cours d'eau, la hauteur des galeries et le matériau exploité. Les relations avec le diamètre des effondrements ont été explorées par des analyses statistiques.

Une analyse spécifique des variables qualitatives a mis en évidence l'influence du matériau exploité sur le diamètre des effondrements (Figure 1) : la craie présente de grands diamètres avec une forte variabilité, le calcaire des diamètres élevés mais plus homogènes, et le gypse des effondrements généralement petits et homogènes. La géomorphologie (verticale et horizontale) montre également des tendances intéressantes.

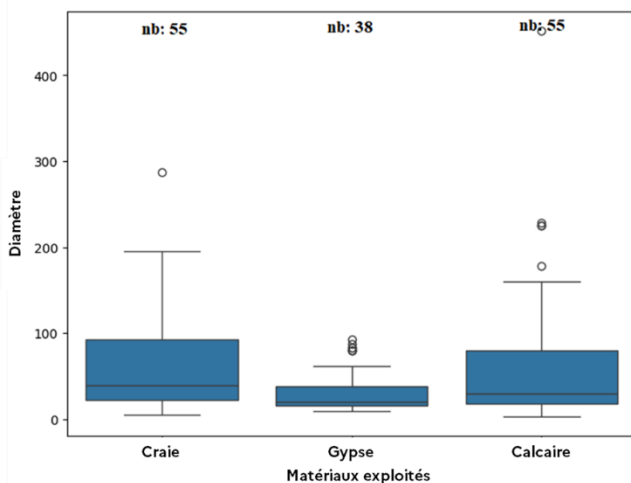


Figure 1 Diamètre d'effondrement (en m) en fonction du matériau exploité

Pour mieux comprendre les interactions entre les facteurs, une analyse multivariée a ensuite été menée. Les résultats indiquent que les effondrements de plus grand diamètre sont souvent associés à une proximité d'un cours d'eau et confirme la sensibilité aux taux de défrèvement élevés, particulièrement pour le calcaire (Figure 2). Certaines configurations géomorphologiques, telles que les éperons ou corniches, favorisent également des effondrements plus importants, surtout pour la craie et le calcaire. Le gypse se distingue par des effondrements de petite taille, indépendamment des autres facteurs.

À l'issue de cette phase de préparation et d'analyse, six variables clés ont été retenues pour la modélisation : cinq variables d'entrée regroupées en deux catégories, exploitation (matériau extrait et taux d'exploitation) et environnement (distance au thalweg,

géomorphologie 1 et géomorphologie 2), et une variable de sortie correspondant au diamètre en surface des effondrements. Le taux de valeurs manquantes dans le jeu final a été réduit à 14 %.




Figure 2 Relation entre la Distance au Thalweg, le Taux de Défrèvement, le Diamètre d'Effondrement et le Matériau Exploité

Une description des six variables est présentée dans le Tableau 1. Les variables géomorphologie 1 et 2 sont schématisées sur la Figure 3.

Tableau 1. Description des variables retenues de la base de données

Variable	Description	Catégorie
Matériau extrait	Type de matériau extrait (calcaire, craie, gypse)	Exploitation
Taux d'exploitation	Taux moyen d'exploitation de la carrière	Exploitation
Géomorphologie 1	Position de la carrière par rapport à la vallée	Environnement de la carrière
Géomorphologie 2	Caractéristiques géomorphologiques autour de la carrière	Environnement de la carrière
Distance au cours d'eau	Distance au cours d'eau	Environnement de la carrière
Diamètre en surface	Diamètre de l'effondrement (en mètre)	Effondrement




Figure 3. Paramètres géomorphologiques (géomorphologie 1 et géomorphologie 2)

3.3.2 Variable de sortie : diamètre d'effondrement

Afin de faciliter l'application des méthodes d'apprentissage automatique, le diamètre

d'effondrement en surface, initialement défini comme une variable quantitative, a été transformé en une variable catégorielle. Cette étape a permis de définir une variable cible, désignée comme « ampleur de l'effondrement », structurée en trois classes : petit effondrement (0), effondrement modéré (1) et grand effondrement (2).

Les seuils de classification ont été choisis de manière à obtenir une répartition équilibrée des effectifs entre les classes, condition nécessaire pour garantir la robustesse des modèles d'apprentissage et limiter les biais liés à un déséquilibre des données. Une distribution homogène des classes favorise en effet un entraînement équitable du modèle et améliore les performances de prédiction, notamment pour les classes extrêmes. La Figure 8 présente la distribution des diamètres d'effondrement observés et la répartition finale des cas au sein des trois classes définissant la variable de sortie.




Figure 4. Distribution de la variable de sortie (Guayacán-Carrillo et al. 2025)

4 MÉTHODOLOGIE D'APPRENTISSAGE AUTOMATIQUE

4.1 Démarche méthodologique

Compte tenu de la taille limitée et de l'hétérogénéité de la base de données, une méthodologie d'apprentissage automatique structurée a été mise en œuvre afin de limiter les risques de surapprentissage et d'assurer la robustesse des résultats. La méthodologie comprend les étapes suivantes : (i) prétraitement et imputation des données manquantes, (ii) sélection des descripteurs pertinents, (iii) définition de la variable cible, (iv) entraînement et validation des modèles, (v) évaluation des performances sur des jeux de test indépendants, et (vi) analyse critique des résultats.

4.2 Méthodes d'apprentissage

4.2.1 Recours aux méthodes ensemblistes

L'utilisation de jeux de données restreints est susceptible d'induire un surapprentissage des modèles d'apprentissage automatique. Plusieurs travaux récents ont montré que les méthodes ensemblistes permettent de limiter ce risque en combinant les

prédictions de plusieurs modèles élémentaires, améliorant ainsi la généralisation (Richa et al. 2025 ; Tristani et al. 2024). Cette famille de méthodes est particulièrement adaptée aux problématiques géotechniques, où les données sont souvent peu nombreuses et hétérogènes (Phoon et Zhang 2023;)

4.2.2 Forêts aléatoires

La forêt aléatoire (Random Forest), introduite par Breiman (2001), repose sur l'agrégation de multiples arbres de décision construits à partir de sous-échantillons aléatoires. Cette approche réduit la variance du modèle et limite le surapprentissage grâce à un mécanisme de vote majoritaire. Elle est largement utilisée en géotechnique pour des problèmes de classification et de régression (Zhou et al. 2017; Xie et Peng 2019) et a été retenue comme modèle principal dans cette étude. En complément, des méthodes de gradient boosting ont également été évaluées afin d'explorer leur capacité à capter des relations non linéaires complexes entre les variables, bien que leur sensibilité au surapprentissage impose une attention particulière dans le contexte de bases de données réduites.

4.2.3 Gestion des données manquantes et stratégie d'entraînement

Comme vu précédemment la base de données finale comprend 143 cas, avec environ 14 % de valeurs manquantes. Afin de préserver l'information disponible, une imputation des données manquantes a été réalisée à l'aide de l'algorithme MissForest, reconnu pour sa capacité à traiter simultanément des variables quantitatives et qualitatives (Stekhoven et Bühlmann 2012).

Après imputation, les données ont été divisées en trois sous-ensembles : un jeu de validation indépendant (10 cas), puis un partage des données restantes entre entraînement (70 %) et test (30 %). Une validation croisée (k-fold) a été appliquée afin d'évaluer la stabilité des performances.

4.2.4 Enrichissement par données synthétiques

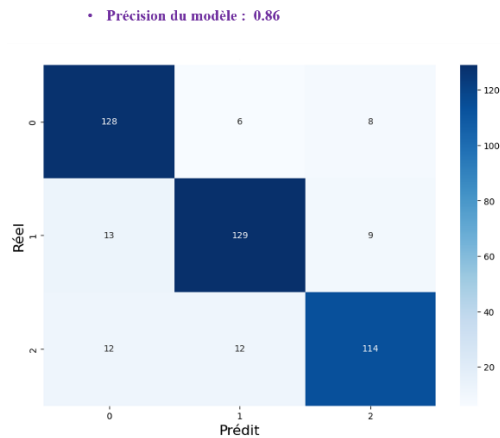
Afin de pallier la faiblesse de l'échantillon d'apprentissage, la méthode SMOTE (Synthetic Minority Over-sampling Technique ; Fernandez et al. 2018) a été testée. Bien que conçue initialement pour traiter les déséquilibres de classes, cette méthode a été utilisée ici pour générer des données synthétiques à partir des plus proches voisins, dans l'objectif d'augmenter la taille effective de l'ensemble d'entraînement. Plusieurs niveaux d'augmentation ont été explorés, mettant en évidence une amélioration

notable des performances théoriques des modèles avec l'enrichissement des données.

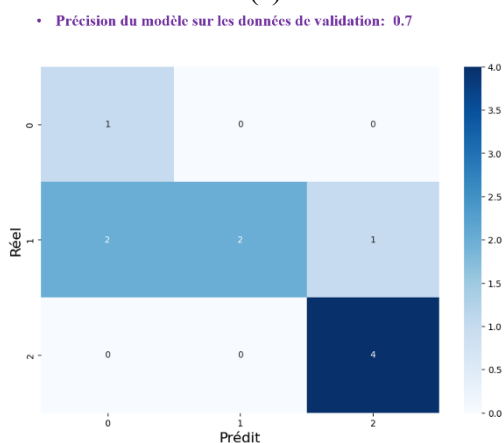
4.2.5 Évaluation et limites

L'évaluation des performances repose principalement sur l'analyse des matrices de confusion sur les données test puis de validation et des indicateurs de précision globale (Figure 5). Les résultats montrent de meilleures performances pour les classes extrêmes (petits et grands effondrements) que pour la classe intermédiaire, traduisant un chevauchement des caractéristiques entre ces catégories.

Néanmoins malgré l'amélioration apportée par l'utilisation des données synthétiques, les performances restent limitées par la taille et la qualité de la base initiale et tributaire du faible nombre de données de validation.



(a)



(b)

Figure 5. Matrice de confusion pour les données de tests (a) et de validation (b) obtenues après l'entraînement d'un modèle avec génération de données synthétiques.

5 MISE EN OEUVRE D'UN OUTIL RAG

Suite à cette première étude il apparait nécessaire d'améliorer la qualité de la base de données en

particulier en augmentant le taux de remplissage. Afin d'accélérer et fiabiliser l'intégration des données, une méthode d'extraction automatique de données a été déployée pour renseigner les variables de l'inventaire. Les avancées récentes en intelligence artificielle, et plus particulièrement en traitement automatique du langage naturel, ouvrent de nouvelles perspectives pour l'exploitation de documents techniques volumineux. Parmi ces approches, la Retrieval-Augmented Generation (RAG) apparaît particulièrement prometteuse. Elle repose sur la combinaison de deux étapes complémentaires : (i) une phase de recherche documentaire (retrieval), visant à identifier, au sein d'un corpus de documents, les passages les plus pertinents en réponse à une requête formulée en langage naturel ; et (ii) une phase de génération augmentée (augmented generation), au cours de laquelle un modèle de langage exploite ces passages pour produire une réponse ciblée ou extraire des informations structurées.

Appliquée aux documents qui ont permis la création de l'inventaire, cette approche présente plusieurs avantages : l'ingestion et le prétraitement automatisés de grands volumes de rapports PDF hétérogènes ; l'identification rapide de sections pertinentes relatives à un évènement donné ; l'extraction et la structuration d'informations clés (identifiants, dates, coordonnées, descriptions des phénomènes) ; l'alimentation fiable de la base de données, réduisant ainsi la dépendance à une lecture manuelle chronophage ; et la facilitation des mises à jour lors de l'intégration de nouveaux documents.

Le système de Retrieval-Augmented Generation (RAG) utilisé dans cette étude a été développé dans un environnement Jupyter Notebook et repose sur une architecture standard combinant recherche documentaire et génération de texte. Après préparation de l'environnement de calcul, deux modèles sont mobilisés : un modèle de langage pour la génération de réponses (Gemma 3 4B IT) et un modèle d'embeddings (all-mpnet-base-v2) pour la vectorisation des contenus textuels.

Les rapports PDF sont extraits puis découpés en fragments textuels d'environ 1 000 caractères avec chevauchement, afin de préserver le contexte. Ces fragments sont vectorisés et indexés dans une base de données vectorielle (ChromaDB). Lorsqu'une requête est formulée, elle est comparée aux fragments indexés afin d'identifier les passages les plus pertinents, qui sont ensuite exploités par le modèle de génération pour produire une réponse contextualisée (Figure 3).



Figure 6. Étape du RAG : question, vectorisation, recherche, génération d'une réponse.

Si cette architecture s'avère efficace pour des usages exploratoires de type question-réponse, la complexité et l'hétérogénéité des rapports PDF ont limité l'extraction automatisée exhaustive des variables d'intérêt. Des optimisations de l'architecture et des stratégies d'interrogation ont donc été dû être mises en œuvre. Ainsi l'architecture RAG a été optimisée afin d'améliorer l'extraction et la structuration des informations issues de rapports PDF hétérogènes. Les évolutions portent principalement sur l'amélioration de l'extraction des tableaux et des contenus issus d'images, un découpage des textes préservant la cohérence sémantique, une vectorisation et une indexation plus performantes, ainsi qu'un mécanisme de recherche hybride combinant similarité sémantique et critères lexicaux. Le modèle de génération a également été renforcé par l'adoption d'un LLM¹ de plus grande capacité, permettant d'améliorer la qualité et la fiabilité des réponses.

La mise en œuvre du RAG au sein de la base documentaire de l'inventaire est actuellement en cours. À l'issue de cette phase, une vérification rigoureuse par des experts en géotechnique sera menée afin de contrôler la pertinence, la cohérence et l'interprétabilité des informations extraites. Le modèle d'apprentissage automatique sera ensuite testé à nouveau, de manière à évaluer objectivement les améliorations induites par l'usage du RAG.

6 CONCLUSIONS

Depuis plusieurs années, l'Ineris développe une approche innovante fondée sur l'apprentissage automatique, appliquée à des bases de données construites à partir de mesures in situ ou issues de retours d'expérience (effondrements, signaux acoustiques, etc.). Cette démarche repose sur une structuration rigoureuse des différentes étapes, depuis le prétraitement, la sélection et la validation des données, jusqu'à l'entraînement, la validation et le déploiement des modèles. Plusieurs méthodes d'apprentissage ont été évaluées, notamment des approches ensemblistes, qui se sont révélées satisfaisantes pour ces premiers travaux exploratoires.

¹ LLM (Large Language Model) : modèle d'intelligence artificielle entraîné sur de grands volumes de textes, capable

L'un des principaux verrous mis en évidence concerne toutefois la qualité des bases de données disponibles, ainsi que le nombre souvent limité de cas exploitables. Le recours à des méthodes de génération de données synthétiques a permis d'améliorer les performances des modèles, mais demeure insuffisant pour aboutir, à ce stade, à des modèles prédictifs pleinement robustes. Afin de répondre à cette problématique, l'Ineris a mis en œuvre un système de type Retrieval-Augmented Generation (RAG), visant à enrichir automatiquement les bases de données par l'extraction ciblée d'informations issues de documents techniques. Les premiers résultats obtenus sont encourageants, bien que des optimisations restent nécessaires pour un usage opérationnel optimal. Néanmoins, si l'approche RAG constitue un apport méthodologique prometteur pour l'extraction des données nécessaire aux analyses, elle ne saurait en aucun cas se substituer à une vérification humaine experte, indispensable pour garantir la fiabilité, la cohérence et l'interprétation des résultats.

À terme, l'objectif est de développer des outils prédictifs accessibles et directement exploitables par les ingénieurs. Dans cette perspective, des méthodes de régression symbolique seront mises en œuvre (Guayacán-Carrillo et Sulem 2024). Celles-ci permettront de produire des expressions mathématiques explicites reliant les variables d'entrée et de sortie, renforçant ainsi l'interprétabilité et la pertinence des modèles, tout en facilitant une prise de décision éclairée.

À travers ces travaux, l'Ineris met en évidence l'intérêt de combiner la puissance de calcul des approches d'intelligence artificielle avec l'expertise géotechnique humaine, afin de développer des outils fiables, interprétables et adaptés aux enjeux opérationnels, qu'ils soient de nature prédictive ou orientés vers l'enrichissement et l'exploitation des connaissances. Ces outils visent, à terme, à améliorer l'évaluation et la gestion des risques d'effondrement dans les carrières souterraines abandonnées.

REFERENCES BIBLIOGRAPHIQUES

- Al Heib, Marwan, Nathalie Conil, et Philippe Gombert. 2023. « Influence of Geology and Topography on the Occurrence of Mine Massive Collapse—Back-Analysis of a Historical Collapse of Chalk Mine (France) ». *Bulletin of Engineering Geology and the Environment* 82 (6): 230. <https://doi.org/10.1007/s10064-023-03234-z>.

de comprendre, générer et analyser du langage naturel en s'appuyant sur des réseaux de neurones de grande taille.

- Bennani, Mustapha, Christian Bouffier, et Christian Franck. 2016. *Guide de surveillance des cavités souterraines d'origine anthropique*. Appui Ineris-DRS-16-156834-00810B.
- Breiman, Leo. 2001. « Random Forests ». *Machine Learning* 45 (1): 5-32. <https://doi.org/10.1023/A:1010933404324>.
- Conil, Nathalie, et Philippe Gombert. 2024. « Amélioration de la connaissance des mécanismes d'instabilité et de l'impact du changement climatique sur les carrières souterraines abandonnées en France : premiers résultats | Ineris ». novembre 25. <https://www.ineris.fr/fr/amelioration-connaissance-mecanismes-instabilite-impact-changement-climatique-carrieres>.
- Conil, Nathalie, Philippe Gombert, Marwan Al Heib, et al. 2023. « An underground research laboratory at Château-Landon (France) to study the impact of climate change on the stability of abandoned mines ». *Bulletin of Engineering Geology and the Environment* 82 (1): 11. <https://doi.org/10.1007/s10064-022-03028-9>.
- Drif, Karim Kamel, A. Mohmoh, et Nathalie Conil. 2025. « Automatic Classification of Acoustic Signals for Rockfall Detection in an Abandoned Chalk Mine Using Machine Learning ». In *ISRM European Rock Mechanics Symposium (EUROCK 2025)*, édité par International Society for Rock Mechanics et Rock Engineering-Norwegian Group for Rock Mechanics. Trondheim, Norway. <https://ineris.hal.science/ineris-05312178>.
- Fernandez, Alberto, Salvador Garcia, Francisco Herrera, et Nitesh V. Chawla. 2018. « SMOTE for Learning from Imbalanced Data: Progress and Challenges, Marking the 15-year Anniversary ». *Journal of Artificial Intelligence Research* 61 (avril): 863-905. <https://doi.org/10.1613/jair.1.11192>.
- Guayacán-Carrillo, Lina-María, Nathalie Conil, et A. Kadri. 2025. « Using Machine Learning for Predicting Collapse extending in Abandoned Underground Mines ». In *ISRM European Rock Mechanics Symposium (EUROCK 2025)*, édité par International Society for Rock Mechanics et Rock Engineering-Norwegian Group for Rock Mechanics. Trondheim, Norway. <https://hal.science/hal-05312019>.
- Guayacán-Carrillo, Lina-María, et Jean Sulem. 2024. « Symbolic Regression Based Prediction of Anisotropic Closure in Deep Tunnels ». *Computers and Geotechnics* 171 (juillet): 106355. <https://doi.org/10.1016/j.compgeo.2024.106355>.
- Phoon, Kok-Kwang, et Wengang Zhang. 2023. « Future of machine learning in geotechnics ». *Georisk: Assessment and Management of Risk for Engineered Systems and Geohazards* 17 (1): 7-22. <https://doi.org/10.1080/17499518.2022.2087884>.
- Richa, Tatiana, Lina-María Guayacán-Carrillo, Jean-Michel Pereira, et Gilles Chapron. 2025. « Apprentissage automatique en géotechnique : étude de cas dans le domaine des tunnels ». *Mécanique des sols et géotechnique*, publication en ligne anticipée, mai. <https://doi.org/10.51257/a-v1-c231>.
- Stekhoven, Daniel J., et Peter Bühlmann. 2012. « MissForest—Non-Parametric Missing Value Imputation for Mixed-Type Data ». *Bioinformatics* 28 (1): 112-18. <https://doi.org/10.1093/bioinformatics/btr597>.
- Tristani, A., L.M. Guayacán-Carrillo, et J. Sulem. 2025. « A physics-informed machine learning surrogate model to assess the long-term ground-lining interaction in viscoelastic plastic grounds. » *59th U.S. Rock Mechanics/Geomechanics Symposium*, juin 8, D041S056R001. <https://doi.org/10.56952/ARMA-2025-0533>.
- Tritsch, Jean-Jacques, Christophe Didier, et Mehdi Ghoreychi. 2007. *Mise en sécurité des cavités souterraines d'origine anthropique Surveillance - Traitement*. Appui Ineris-DRS-07-86042-02484.
- Xie, Qiang, et Kang Peng. 2019. « Space-Time Distribution Laws of Tunnel Excavation Damaged Zones (EDZs) in Deep Mines and EDZ Prediction Modeling by Random Forest Regression ». *Advances in Civil Engineering* 2019 (1): 6505984. <https://doi.org/10.1155/2019/6505984>.
- Zhou, Jian, Xiuzhi Shi, Kun Du, Xianyang Qiu, Xibing Li, et Hani S. Mitri. 2017. « Feasibility of Random-Forest Approach for Prediction of Ground Settlements Induced by the Construction of a Shield-Driven Tunnel ». *International Journal of Geomechanics* 17 (6): 04016129. [https://doi.org/10.1061/\(ASCE\)GM.1943-5622.0000817](https://doi.org/10.1061/(ASCE)GM.1943-5622.0000817).