

# Détection automatique des dégradations à potentiel géotechnique sur les infrastructures routières par intelligence artificielle

## Automatic detection of geotechnical-related distresses on road infrastructures using artificial intelligence

Salma CHIADMI<sup>1</sup>, Bakri BASMAJI<sup>1\*</sup>, Adel ABDALLAH<sup>2</sup>, Vincent COIN<sup>3</sup>, Laurent Sylvestre<sup>1</sup>

*1 Cerema, 1 Nancy, France*

*2 Lemta, 2 Nancy, France*

*3 DIR Est, 3 Metz, France*

*\*bakri.basmaji@cerema.fr*

**RESUME :** Les infrastructures routières subissent diverses dégradations dont certaines relèvent de désordres géotechniques (retrait-gonflement des argiles, glissements de terrain, affaissements de sol). En l'absence de validation par un géotechnicien, cette origine n'est pas toujours mise en évidence lors des diagnostics, ce qui accroît les risques pour les usagers, aggrave les désordres et renchérit la maintenance.

Ce travail développe un outil d'aide à la décision pour la détection automatisée des dégradations à potentiel géotechnique sur les routes. Pour ce faire, un réseau de neurones convolutif a été entraîné sur des images d'inspection routière acquises par le Cerema dans la région Grand Est depuis 2008 et annotées par des spécialistes. L'ensemble des données a été réparti en 80 % pour l'entraînement et 20 % pour la validation. Sur cette itération initiale, la précision a atteint 70 % sur le jeu de validation. Ce résultat préliminaire confirme la faisabilité et une phase d'optimisation est en cours.

Les dégradations détectées ont ensuite été caractérisées à partir des informations géoréférencées associées, en combinant des critères visuels et contextuels liés aux facteurs déclencheurs et aggravants des désordres géotechniques. Ces critères sont pondérés afin de hiérarchiser les dégradations selon leur probabilité d'origine géotechnique et d'orienter en priorité l'intervention des géotechniciens sur les zones à risque.

Le projet constitue un atout pour la surveillance des réseaux : il systématise la détection des dégradations, priorise les zones à risque et guide plus efficacement l'expertise terrain. Les principales limites tiennent à la complexité des phénomènes géotechniques, difficilement inférables à partir de seules données de surface, et à l'absence d'historique d'images sur certains réseaux, qui restreint l'analyse de la répétabilité des dégradations. Malgré ces contraintes, l'approche ouvre la voie à une maintenance plus proactive, ciblée et optimisée.

**ABSTRACT:** Road infrastructure deteriorates in many ways, and some of these defects are linked to geotechnical issues (such as shrink–swell of clay soils, landslides, or ground settlement). When there is no formal assessment by a geotechnical engineer, this origin is not always identified during condition surveys, which increases risks for road users, worsens the damage over time, and drives up maintenance costs.

This work presents a decision-support tool for the automatic detection of road surface defects with potential geotechnical causes. To this end, a convolutional neural network was trained on road inspection images collected by Cerema in the Grand Est region since 2008 and annotated by domain experts. The dataset was split into 80% for training and 20% for validation. On this first iteration, the model achieved 70% accuracy on the validation set. These preliminary results confirm the feasibility of the approach, and an optimization phase is currently under way.

The detected defects were then further characterized using the associated georeferenced information, combining visual indicators with contextual factors related to the triggering and aggravating mechanisms of geotechnical phenomena. These criteria are weighted to rank defects according to their likelihood of having a geotechnical origin, so that geotechnical investigations can be directed first toward the highest-risk areas.

This project strengthens road network monitoring by systematizing defect detection, prioritizing at-risk zones, and guiding on-site expert assessment more efficiently. The main limitations relate to the inherent complexity of geotechnical processes, which are difficult to infer from surface data alone, and to the lack of long-term image archives on some networks, which

restricts the analysis of defect recurrence. Despite these constraints, the approach paves the way for more proactive, targeted, and optimized maintenance strategies.

**Mots-clés: Résilience infrastructures routière ; Gestion du patrimoine routier ; Dégradations d'origine géotechnique ; Vision par ordinateur ; Deep Learning**

## 1 INTRODUCTION

Les infrastructures routières connaissent diverses dégradations, dont certaines sont dues à des désordres géotechniques. Plusieurs méthodes de surveillance des dégradations des chaussées sont utilisées par les gestionnaires. Parmi ces méthodes :

- Sur le réseau de l'État : un suivi par la méthode Aigle3D [1] est adopté depuis 2018
- Pour d'autres types de structures : un suivi visuel ou par d'autres méthodes à haut rendement.

L'efficacité de ces méthodes a été prouvée pour le suivi des dégradations d'origine structurelle des chaussées. En revanche, les dégradations d'origine géotechnique sont détectées mais généralement assimilées à tort au processus courant de dégradation structurelle de la route et non à une pathologie d'origine géotechnique.

Les avancées récentes en vision par ordinateur et en Deep Learning offrent une opportunité pour automatiser et homogénéiser la détection des dégradations à partir d'images d'auscultation. Ces approches ont ainsi gagné en popularité dans le contexte de la surveillance routière [2,3]. Plusieurs initiatives ont notamment conduit à la constitution de jeux de données dédiés à la détection de dégradations de chaussées, comme le défi CRDDC'2022 [4]. Toutefois, ces bases ne couvrent pas ou très peu certaines dégradations de surface que nous souhaitons cibler pour le diagnostic géotechnique, en particulier certains types de fissures longitudinales, les purges et les fissures scellées. En l'absence de base de données propre à ces dégradations, une base dédiée a été constituée et annotée afin d'entraîner un modèle de Deep Learning adapté à cet objectif.

Au-delà de la seule détection, une seconde étape associe automatiquement chaque dégradation détectée à son contexte environnemental et à des critères morphologiques aggravants, à partir des informations géoréférencées disponibles. Ces informations sont combinées pour hiérarchiser les dégradations en fonction du niveau de risque associé. L'outil en cours de développement se positionne ainsi comme un système d'aide à la décision : il systématise la

détection des dégradations ciblées, met en évidence les zones les plus susceptibles de receler un désordre d'origine géotechnique et guide la mobilisation des géotechniciens vers les tronçons à investiguer en priorité. Cette démarche répond aux attentes des gestionnaires routiers qui vise à limiter l'exposition des agents sur site et à cibler en priorité les zones susceptibles de représenter un enjeu majeur.

## 2 CONTEXTE GEOTECHNIQUE

### 2.1 Phénomènes géotechniques

Le Retrait-Gonflement des Argiles (RGA) correspond aux variations de volume de certains sols argileux en fonction de leur teneur en eau : les phases sèches provoquent un retrait et des tassements différentiels, les phases humides un gonflement. Ces mouvements lents peuvent engendrer des déformations et des fissures au droit des chaussées. Le risque associé au RGA est appelé à s'accroître avec le changement climatique, en raison de la fréquence accrue des alternances entre sécheresses marquées et réhumidifications rapides [5].

Les glissements de terrain désignent des déplacements d'une masse de sol le long d'une surface de rupture. Dans le cas des infrastructures routières, ils affectent plus particulièrement certains ouvrages en terre, notamment les déblais et remblais de versant, où ils peuvent se manifester par des déplacements différentiels de la plateforme et des fissures longitudinales. Ces phénomènes constituent des sources majeures de désordres géotechniques susceptibles d'impacter la stabilité et la durée de vie des chaussées.

Par ailleurs, il a été constaté ces dernières années une augmentation importante des dégradations d'origine géotechnique, liées en grande partie au changement climatique (retrait-gonflement des argiles, glissements, érosion etc.). Cela souligne l'importance de détecter ces dégradations le plus tôt possible afin de proposer des solutions adaptées.

Ces phénomènes se traduisent en surface par des dégradations caractéristiques des chaussées ; la section suivante précise la typologie des dégradations retenues

comme indicateurs potentiels de désordres géotechniques.

## 2.2 Typologie de dégradations ciblées

À partir de l'expérience développée lors de la préparation de ce travail, il a été constaté que les dégradations de surface, observables visuellement et détectables automatiquement par l'IA, peuvent être classées en trois catégories.

- **Fissures longitudinales ou en arc de cercle** : elles peuvent indiquer une dégradation typique due au RGA ou à un glissement de sol.
- **Fissures scellées** : fissures traitées par un produit de scellement bitumineux, apparaissant comme un tracé linéaire sombre et continu. Suite aux premières fissures, les gestionnaires peuvent les sceller pour réduire l'infiltration d'eau et préserver ainsi la structure des chaussées et la qualité du sol support.
- **Purges** : pour les fissures les plus graves, un simple scellement n'est pas suffisant, et une purge de la couche de surface peut être effectuée, cela correspondant au remplacement localisé d'une zone de chaussée dégradée, généralement visible en surface par une plage de matériau généralement plus foncé ou de texture différente



(a) (b)  
Figure 1 : Exemple de fissure longitudinale due à un RGA (a) et à un glissement de terrain (b). Source : Cerema

Le gestionnaire, en premier lieu, sauf à disposer des compétences adéquates, peut avoir effectivement tendance à sous-estimer le risque et déclencher des travaux inadaptés de surface qui vise à restaurer la planéité et l'étanchéité de la chaussée, pour garantir au moins la sécurité (objectif premier).

Les phénomènes géotechniques étant évolutifs, l'absence de dégradation visible à un instant donné ne garantit pas l'absence de désordre profond, et la réparation d'une fissure liée à un mouvement

géotechnique ne traite pas la cause sous-jacente. Les réparations successives à courte échéance et aux mêmes emplacements deviennent dès lors des indicateurs directs de l'historique et de la récurrence des désordres.



(a) (b)  
Figure 2 : Exemple de purge (a) et de fissure scellée (b). Source : Cerema

Dans la suite, fissures longitudinales, purges et fissures scellées sont ainsi retenues comme classes cibles pour la détection automatique et l'analyse du potentiel géotechnique.

## 3 REVUE BIBLIOGRAPHIQUE

### 3.1 Méthodes de détection d'objets basées sur le Deep Learning

La détection d'objets par Deep Learning se divise en deux familles. Les méthodes en deux étapes, comme Faster R-CNN [6], isolent d'abord des régions candidates avant de les classifier. Très précises sur les petits objets, elles sont toutefois pénalisées par une architecture lourde peu adaptée au temps réel. À l'inverse, les modèles en une étape comme SSD [7] ou YOLO [8] traitent la détection comme un unique problème de régression. L'architecture de YOLO s'organise en trois parties : un réseau de convolution qui extrait des caractéristiques de l'image (bords, textures puis formes), un réseau de fusion multi-échelles pour mieux gérer les objets petits/grands, et une tête de détection qui prédit, pour chaque zone, la classe, la boîte englobante et un score de confiance. En divisant l'image en une grille pour tout traiter en un seul passage, YOLO permet une détection instantanée. Si les petits objets restaient un défi, les versions récentes (jusqu'à YOLOv11) sont désormais beaucoup plus robustes.

Dans le domaine routier, les travaux s'appuyant sur des jeux de données comme RDD2022 privilégient majoritairement les variantes de YOLO, souvent enrichies

par de l'augmentation de données [4]. Ces performances confirment le choix d'une architecture YOLO pour ce projet.

## 4 STRATEGIE DE TRAVAIL

Les phénomènes de RGA ou de glissements de terrains se traduisent en surface principalement par des fissures longitudinales, mais l'inverse n'est pas vrai : la majorité des fissures longitudinales observées n'est pas d'origine géotechnique. Les seules images de chaussée ne permettent donc pas de qualifier de manière fiable l'origine des dégradations. La stratégie retenue est en deux temps : (i) détecter automatiquement les dégradations ciblées (fissures longitudinales, purges, fissures scellées), puis (ii) analyser leur contexte environnemental à l'aide d'indicateurs aggravants afin d'estimer leur potentiel géotechnique et de hiérarchiser les situations à investiguer en priorité.

## 5 DONNEES

Avant de pouvoir entraîner un modèle de détection, il a d'abord fallu réunir une base d'images contenant les dégradations que l'on souhaite cibler. Nous avons donc constitué un jeu de données adapté aux fissures longitudinales, aux purges et aux fissures scellées. La suite de cette section présente les sources de données retenues et la façon dont elles ont été préparées.

### 5.1 Source de données

Deux sources principales sont mobilisées ;

-Images IRCAN du Cerema [9] : Depuis 2008, des campagnes régulières d'auscultation sont menées sur les routes nationales de la Région Grand Est à l'aide de véhicules d'inspection équipés de caméras embarquées, produisant des images géoréférencées acquises tous les 3 ou 5 m. Celles-ci sont associées à un repère linéaire, ce qui facilite le suivi temporel des dégradations.

-Base publique RDD2022 [4] : jeu multinational de plus de 40 000 images de routes, annotées en plusieurs classes de dégradations (fissures longitudinales, fissures transversales, faïençages, nids de poule). Un sous-ensemble de cette base, présentant un point de vue et une composition des scènes proches des acquisitions IRCAN a été retenu pour compléter la classe des fissures longitudinales.

Les images Cerema ont été prioritairement exploitées pour les purges et fissures scellées, très peu représentées dans les bases publiques, ainsi que pour les fissures longitudinales observées sur des secteurs sensibles au retrait-gonflement des argiles.

### 5.2 Sélection et équilibrage de la base de données

Afin de constituer un jeu d'apprentissage homogène, certaines sources de RDD2022 ont été écartées (images très haute résolution, vues drone ou moto, point de vue trop éloigné des conditions d'acquisition IRCAN). Un premier modèle YOLO entraîné sur RDD2022 a été utilisé pour pré-annoter les fissures longitudinales sur les images Cerema.

Le jeu de données annoté comprend 2337 images Cerema et 1000 images RDD2022, soit 3337 images au total. Il est réparti en 80 % entraînement (2670 images) et 20 % validation (667 images). L'évaluation par inférence est réalisée sur 500 images Cerema non annotées constituant le jeu de test.

Les annotations totalisent 2500 fissures longitudinales, 1 568 purges et 1 243 fissures scellées. Le nombre plus élevé de fissures longitudinales s'explique mécaniquement par leur cooccurrence fréquente avec les purges et/ou les fissures scellées au sein d'une même image, ce qui augmente naturellement leur nombre d'instances par rapport aux deux autres classes.

## 6 EXPERIMENTATIONS

### 6.1 Comparaison de modèles

Dans le cadre de cette étude, plusieurs versions récentes de la famille YOLO ont été testées afin d'identifier l'architecture la plus adaptée à la détection des fissures longitudinales, des purges et des fissures scellées sur notre jeu de données. Un premier ensemble d'expérimentations a été mené avec YOLOv7 largement diffusé et documenté qui nous sert de référence. Cette version introduit des améliorations d'architecture et de stratégie d'entraînement (meilleure exploitation de l'information à différentes échelles, optimisation des têtes de détection) et permet en général des gains de précision à configuration comparable. Enfin, YOLOv9 s'appuie sur des mécanismes d'apprentissage plus récents pour renforcer la qualité des prédictions, en particulier dans des scènes complexes et pour des objets de petite taille. Une comparaison expérimentale de ces deux modèles a été réalisée sur la base de données construite dans ce

travail, afin de sélectionner la version offrant les meilleurs résultats pour les dégradations ciblées.

## 6.2 Stratégies de ré-entraînement

Deux stratégies de réentraînement ont été étudiées :

- Stratégie 1 (séquentielle) : un YOLOv7 pré-entraîné sur le jeu COCO [10] puis RDD2022 (4 classes) est adapté en ajoutant deux classes (purges, fissures scellées). Le backbone est figé et seule la tête de détection est réentraînée sur les images Cerema.
- Stratégie 2 (conjointe sur jeu mixte) : un modèle pré-entraîné sur COCO est réentraîné directement sur un jeu combinant RDD2022 et Cerema, soit en gardant toutes les classes RDD2022, soit en ne conservant que la fissure longitudinale côté RDD2022 pour apprendre 3 classes finales (fissure longitudinale, purge, fissure scellée).

La variante 3 classes de la stratégie 2 (avec YOLOv9) est la plus performante (tableau 3), car elle rééquilibre les données et cible les dégradations clés pour l'analyse géotechnique.

## 6.3 Hyperparamètres

Les principaux choix d'hyperparamètres sont :

- Optimiseur : SGD [11] ;
- Taux d'apprentissage : 0,008 ;
- Taille d'image : 512 pixels ;
- Taille de batch : 16 (contrainte par la mémoire GPU) ;
- Nombre d'epochs : 250.

Des augmentations de données modérées (scale, shear, mosaic, mixup, paste-in) sont utilisées afin d'améliorer la généralisation sans générer de scènes irréalistes (absence de retournement vertical, maintien de la structure typique de la scène routière). Un label smoothing de 0,1 est appliqué pour tenir compte de la variabilité des annotations.

# 7 RESULTATS ET INTERPRETATIONS

## 7.1 Métriques d'évaluation

Afin de comparer de manière contrôlée les différents modèles, deux métriques sont retenues: -La mAP (mean Average Precision) mesure la qualité globale du modèle en combinant précision<sup>1</sup> et rappel<sup>2</sup> sur l'ensemble des classes. Le terme « @0,5 » signifie

qu'une prédiction n'est considérée correcte que si la boîte englobante prédite recouvre suffisamment la dégradation réelle. Ce recouvrement est quantifié par l'Intersection over Union (IoU), définie comme le rapport entre l'aire d'intersection des boîtes prédite et réelle et l'aire de leur union ; une détection est valide si l'IoU est supérieure ou égale à 0,5. -Le F1-score combine en un seul indicateur la précision (part des prédictions correctes parmi toutes les prédictions) et le rappel (part des objets correctement détectés parmi tous les objets réels). Il correspond à la moyenne harmonique de ces deux grandeurs :

$$F1 = 2 \times \frac{Precision \times Rappel}{Precision + Rappel} \quad (1)$$

<sup>1</sup>Précision = proportion de prédictions correctes parmi toutes les prédictions.

<sup>2</sup>Rappel = proportion d'objets réels correctement détectés.

## 7.2 Résultats

Les modèles utilisés par la suite sont récapitulés dans le Tableau 1 et sont tous initialisés à partir de poids pré-entraînés sur COCO. La colonne « Classes détectées » se réfère aux classes du jeu de données RDD2022 ainsi qu'à celles ajoutées dans ce travail : (1) fissure longitudinale, (2) fissure transversale, (3) faïençage, (4) nid de poule, (5) purge, (6) fissure scellée. Enfin, les stratégies 1 et 2 mentionnées dans le

Les modèles M1-YOLOv7-ref et M4-YOLOv9-ref (Tableau 1) sont entraînés sur une partie de RDD2022 et servent principalement de références pour homogénéiser l'annotation des fissures longitudinales entre RDD2022 et les images Cerema.

Les modèles M2, M3 et M5 sont ensuite mobilisés pour analyser la détection des dégradations ciblées, en particulier l'effet des configurations de classes (de six à trois classes) et des stratégies de réentraînement. Enfin, bien que d'autres configurations aient été testées (hyperparamètres et jeux de données), seules ces cinq sont présentées, car elles correspondent aux choix méthodologiques principaux en termes de version de YOLO et de stratégie de réentraînement.

Tableau 1 : Présentation des modèles évalués

Modèle	Origine du modèle	Jeu d'entraînement	Classes détectées	Stratégie d'entraînement
--------	-------------------	--------------------	-------------------	--------------------------

M1–YOLO v7-ref	Pré-entraîné sur COCO	Partie de RDD202 2	1,2,3,4	Modèle de référence
M2–YOLO v7-Strat1	Ré-entraînement de M1	Cerema	1,2,3,4, 5,6	1
M3–YOLO v7-Strat2	Pré-entraîné sur COCO	USA+Cerema	1,2,3,4, 5,6	2
M4–YOLO v9-ref	Pré-entraîné sur COCO	Partie de RDD202 2	1,2,3,4	Modèle de référence
M5–YOLO v9-Strat2	Pré-entraîné sur COCO	USA+Cerema	1,5,6	2

Les résultats obtenus par les modèles de référence sont regroupés dans le tableau 2.

Tableau 2 : Performances obtenues par les modèles de référence

Modèle de référence	mAP@0,5	F1	Précision
M1–YOLOv7-ref	0.54	0.55	59,81%
M4–YOLOv9-ref	<b>0.5870</b>	<b>0.59</b>	<b>69,9%</b>

Les résultats obtenus par le reste des modèles sont regroupés dans le tableau 3.

Tableau 3 : Performances obtenues par les modèles de détection

Modèle	mAP@0,5	F1	Précision
M2–YOLOv7-Strat1	0.1926	0.277	64,83%
M3–YOLOv7-Strat2	0.2780	0.346	42%
M5–YOLOv9-Strat2	<b>0.5357</b>	<b>0.5740</b>	<b>66,07%</b>

La stratégie 1 obtient les plus faibles mAP@0,5 et F1 (tableau 3), en raison d'un oubli catastrophique : le faible nombre d'exemples Cerema pour certaines classes (faïençage, fissures transversales, nids-de-poule) conduit le modèle à les « oublier », malgré une précision correcte sur purges et fissures scellées. Avec la stratégie 2, la mAP@0,5 et F1 augmentent mais la précision baisse légèrement, et le déséquilibre du jeu favorise les classes RDD2022 au détriment des classes cibles (purges, fissures scellées). La meilleure configuration est obtenue avec YOLOv9 et une version restreinte du jeu mixte centrée sur les trois classes visées ; le F1 obtenu se situe dans la plage du top 11 de la compétition CRDDC'2022 [4], indiquant des performances comparables aux meilleures approches publiées sur des jeux similaires.




Figure 3 : Exemple de fissures longitudinales et de purge détectées sur la N4 au PR 5+414,74m

Il est important de souligner que les métriques pénalisent toutefois les « retards de détection » : sur les séquences IRCAN (images tous les 3 ou 5 m), une dégradation peut être manquée sur la première image puis détectée sur la suivante ; comme illustré dans la figure 4, ce qui est compté comme faux négatif sans remettre en cause la capacité de l'outil à signaler la zone à risque.



(a)



(b)

Figure 4 : Exemple de purge manquée sur une image (a) mais détectée quelques mètres plus loin (b)

## 8 HIÉRARCHISATION DES DÉGRADATIONS DÉTECTÉES EN FONCTION DE LEUR POTENTIEL GÉOTECHNIQUE

### 8.1 Critères

Le potentiel géotechnique d'une dégradation peut être estimé en combinant des critères contextuels et morphologiques. D'abord, le type d'ouvrage en terre (section rasante, remblai, déblai, mixte) influence directement la sensibilité aux désordres : les remblais sont notamment plus exposés aux instabilités et mouvements de terrain. Pour l'exploiter de façon systématique, un recensement automatique des ouvrages a été mis en place et croisé avec les images IRCAN géoréférencées, afin d'associer automatiquement chaque image (et chaque dégradation détectée) à son type d'ouvrage.

Ensuite, l'historique des dégradations et réparations constitue un indicateur fort : la réapparition de fissures, purges ou fissures scellées au même endroit suggère un désordre récurrent. Les images IRCAN étant disponibles depuis 2008, le modèle de détection peut être appliqué aux campagnes antérieures pour reconstruire un historique par zone ;

toutefois, cet indicateur sera moins fiable sur les réseaux sans archives anciennes et devra être accompagné d'un niveau de confiance.

Le type de sol joue aussi un rôle important, notamment vis-à-vis des phénomènes de RGA : il est attribué en intersectant la position des dégradations avec les cartes de sols, mais ce critère doit être consolidé en intégrant des données de terrain et l'historique de sondages locaux, au-delà des seules cartes.

La végétation intervient via les échanges hydriques : une forte densité végétale, par l'action des racines, peut renforcer les cycles de gonflement-retrait dans les sols argileux. Aujourd'hui dérivé des données IGN, cet indicateur gagnerait en finesse avec une détection directe sur images routières.

Enfin, des critères morphologiques (longueur, continuité, forme arquée) permettraient de différencier des fissures plutôt superficielles et fragmentées (structure de chaussée) de fissures longues, continues et parfois en arc (mouvements de terrain) ; ils sont définis mais leur extraction automatique à partir de la géométrie des objets détectés n'a pas encore été mise en œuvre.

Finalement, la combinaison et la pondération de ces critères devrait permettre de classer chaque dégradation selon un potentiel géotechnique fort, moyen ou faible.

### 8.2 Exemple

À titre d'illustration, une fissure longitudinale a été détectée en 2023 sur l'autoroute A31, au PR 294+60, comme illustré dans la figure 5.




Figure 5 : Fissure longitudinale détectée en 2023 sur la A31 au PR 294+60

De façon automatique, l'application du modèle de détection sur les campagnes IRCAN antérieures met en évidence, au même emplacement, une fissure longitudinale en 2015 puis une purge en 2016, ce qui traduit la récurrence des dégradations et des interventions. Le croisement automatisé avec les données de contexte indique que la dégradation se situe sur un profil rasant, en contexte de sol argileux, avec une végétation dense à proximité du talus. Visuellement, les critères morphologiques vont dans le même sens (fissure de longueur significative, continue et bien marquée). L'ensemble de ces éléments conduit à classer cette fissure en fort potentiel géotechnique, compatible avec un mécanisme de type retrait-gonflement des argiles. Ce classement est en adéquation avec le diagnostic réalisé par les géotechniciens, qui concluent également à un fort potentiel géotechnique de type RGA pour cette fissure.

## 9 CONCLUSION

Ce travail propose une démarche en deux étapes mobilisant l'IA au service de la géotechnique en lien avec la résilience routière : (1) la détection automatique des fissures longitudinales, purges et fissures scellées via un modèle YOLO entraîné sur un jeu mixte IRCAN/RDD2022, puis (2) par hiérarchisation du potentiel géotechnique des dégradations, en combinant contexte d'ouvrage, type de sol, historique, végétations, et, à terme, critères morphologiques. Le modèle le plus performant (YOLOv9, entraîné sur les trois classes d'intérêt) atteint un F1-score de 57 % et une précision globale de 66 %. Pour la classe fissures longitudinales, la précision est de 70 %. Des travaux sont en cours pour enrichir la base d'images, homogénéiser les annotations et améliorer la détection. Les limites identifiées (sols en remblai, végétation, critères morphologiques, règle de décision) ouvrent des perspectives vers un outil d'aide à la décision plus robuste, intégrable à la gestion patrimoniale pour mieux cibler les investigations et optimiser la maintenance.

## REMERCIEMENTS

Les auteurs remercient la DIR Est et la Région Grand Est pour leur soutien, ainsi que pour le financement de ce projet.

## REFERENCES BIBLIOGRAPHIQUES

- [1]:Accompagner les collectivités vers une gestion patrimoniale innovante des réseaux de transport routes [en ligne], disponible à l'adresse : <https://www.cerema.fr/fr/actualites/accompagner-collectivites-gestion-patrimoniale-innovante>, consulté le 24/12/2025
- [2]: H. Maeda et al., "Road damage detection and classification using deep neural networks with smartphone images," *Computer-Aided Civil and Infrastructure Engineering*, vol. 33, no. 12, pp. 1127–1141, 2018.
- [3]:L. Song and X. Wang, "Faster region convolutional neural network for automated pavement distress detection," *Road Materials and Pavement Design*, vol. 22, no. 1, pp. 23–41, 2021.
- [4]:Arya, D., Maeda, H., Ghosh, S.K., Toshniwal, D. & Sekimoto, Y. (2024) RDD2022: A multi-national image dataset for automatic road damage detection. *Geoscience Data Journal*, 11, 846–862. Available from: <https://doi.org/10.1002/gdj3.260>
- [5]: M.Lestang, « Un chantier expérimental sur la RD3 à Morlac pour répondre à la problématique de retrait-gonflement des sols argileux », *Le Berry Républicain*, 21 septembre 2021 [en ligne]. Disponible sur : [https://www.leberry.fr/morlac-18170/travaux-urbanisme/un-chantier-experimental-sur-la-rd3-a-morlac-pour-repondre-a-la-problematique-de-retrait-gonflement-des-sols-argileux\\_14015006/](https://www.leberry.fr/morlac-18170/travaux-urbanisme/un-chantier-experimental-sur-la-rd3-a-morlac-pour-repondre-a-la-problematique-de-retrait-gonflement-des-sols-argileux_14015006/)
- [6]: S. Ren, K. He, R. Girshick, and J. Sun, "Faster r-cnn: Towards real-time object detection with region proposal networks," in *Advances in neural information processing systems*, 2015, pp. 91–99.
- [7]: Liu, W. *et al.* (2016). SSD: Single Shot MultiBox Detector. In: Leibe, B., Matas, J., Sebe, N., Welling, M. (eds) *Computer Vision – ECCV 2016*. ECCV 2016. *Lecture Notes in Computer Science()*, vol 9905. Springer, Cham. [https://doi.org/10.1007/978-3-319-46448-0\\_2](https://doi.org/10.1007/978-3-319-46448-0_2)
- [8]: J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 779–788.
- [9]:Cerema. Matériels d'acquisition pour routes [en ligne], disponible à l'adresse : <https://ireve.cerema.fr/acquisition/routes>, consulté le 02/12/2025
- [10]:Lin, TY. *et al.* (2014). Microsoft COCO: Common Objects in Context. In: Fleet, D., Pajdla, T., Schiele, B., Tuytelaars, T. (eds) *Computer Vision – ECCV 2014*. ECCV 2014. *Lecture Notes in Computer Science*, vol 8693. Springer, Cham. [https://doi.org/10.1007/978-3-319-10602-1\\_48](https://doi.org/10.1007/978-3-319-10602-1_48)
- [11]:Sebastian Ruder, An overview of gradient descent optimization algorithms, 2016, arXiv preprint arXiv:1609.04747.