

SYSTEME DE VIGILANCE EN LIGNE POUR LES ALEAS GRAVITAIRES EN SAVOIE

ONLINE EARLY WARNING SYSTEM FOR GRAVITATIONAL HAZARDS IN THE SAVOIE DEPARTMENT

Héloïse CADET¹, David ROUQUET², Anne LESCURIER³

¹ SAGE ingénierie, Grenoble, France

² Tétrás Libre

³ Département de la Savoie, service risques naturels

RÉSUMÉ – Un prototype de système de vigilance en ligne pour les aléas gravitaires dans la Savoie a été réalisé en se basant sur l'intelligence artificielle. Les niveaux de vigilance sont le croisement entre des modèles de susceptibilité et des modèles prédictifs. Ces derniers ont réalisé leur apprentissage sur une base de données de glissements de terrain et chutes de blocs sur la période 2008-2020. Ils montrent des métriques performantes.

ABSTRACT – A prototype of an online early-warning system for gravitational hazards in Savoie has been developed based on artificial intelligence. The warning levels result from the intersection of susceptibility and predictive models. The predictive models underwent training using a database of landslides and rockfalls from the period 2008-2020. They exhibit strong performance metrics.

1 Introduction

Face aux constats des conséquences parfois dramatiques des aléas gravitaires en montagne, le besoin d'aide à la décision pour gérer de tels phénomènes est aujourd'hui très présent pour les gestionnaires de territoire. Une des approches est la mise en place de système de vigilance à l'échelle territoriale. Ces systèmes sont largement développés dans le monde et en Europe (Guzzetti et al., 2020), et existent à différentes échelles (de local à mondiale). Cependant, à notre connaissance, il n'y a pas de prototype opérationnel sur le territoire français.

Le projet SIGALE (Système d'Information Géoréférencé des ALEAs gravitaires) vise à développer un système expérimental de vigilance temporelle en ligne pour gérer les aléas gravitaires de type glissement de terrain et chute de blocs, à l'échelle d'un département. Un prototype a été réalisé sur le réseau routier du département de la Savoie (CD73) et de la direction interrégionale des routes centre-Est (DIR-CE). Ce réseau représente environ 3300 km. Ce système utilise l'intelligence artificielle (IA) pour prédire un niveau de vigilance pour chacun de ces deux aléas. Ce niveau est défini par deux termes : un modèle spatial de susceptibilité à l'aléa concerné et un modèle temporel de prédiction de l'aléa. Le présent article se focalise sur les résultats obtenus sur les glissements de terrain uniquement.

Une base de données des glissements de terrain (BDG) a été consciencieusement construite pour l'apprentissage des modèles IA. Ce système de vigilance expérimental est accessible en ligne via un prototype de servie-web, représentant une aide à la décision pour les gestionnaires.

2 Méthodologie

2.1 Base de données

2.1.1 Base de données d'apprentissage

La base de données BDG est construite sur la période 2008-2020. La BDG regroupe 481 glissements de terrain. Ces aléas sont tous datés et géoréférencés, à environ 78% par les agents du département en charge des routes, 2% par la DIR-CE et 20% par les ingénieurs de SAGE ingénierie. La répartition spatiale de ces aléas est donnée sur la Figure 1.

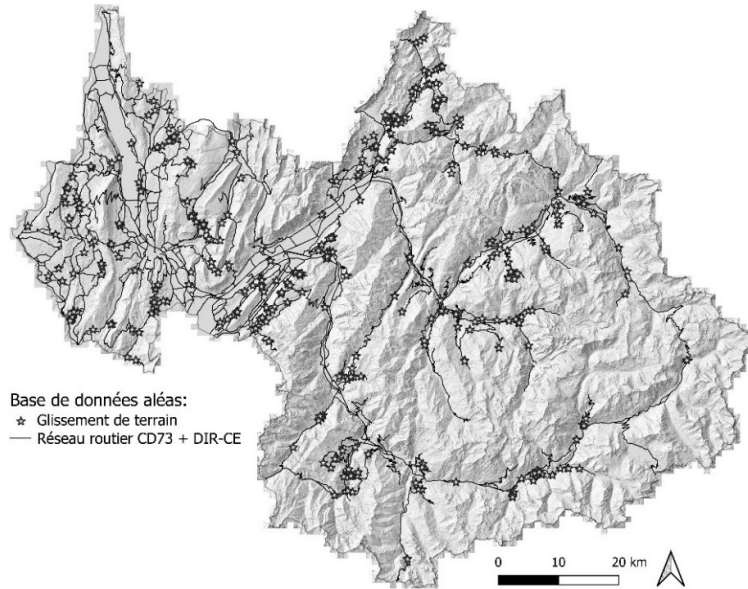


Figure 1. Répartition spatiale des aléas gravitaires en Savoie.

On considère que les dates peuvent être parfois estimées avec un à deux jours de retard, en lien avec une présence réduite des agents durant le week-end. En effet, d'après le tableau suivant, les aléas le samedi sont sous-représentés et sur-représentés les lundi et mardi (la médiane étant de 219 évènements).

Tableau 1 : Répartition du nombre d'aléas selon le jour de la semaine

Jour	Lundi	Mardi	Mercredi	Jeudi	Vendredi	Samedi	Dimanche
Nombre d'aléas	266	282	210	233	219	185	214

Les aléas gravitaires sont très rarement caractérisés par leur volume (une cinquantaine de cas). Les glissements de terrain sont considérés comme ayant des volumes de plusieurs centaines à quelques milliers de mètres cubes, probablement plutôt peu profonds.

Les aléas concernant uniquement les routes gérées par le CD73 et la DIR-CE, le géoréférencement est uniquement fait sur ces routes. Les modèles ne sont donc valables qu'au niveau des routes départementales qui sont régulièrement parcourues par les agents du département. Cette considération nous permet d'émettre l'hypothèse d'une quasi-exhaustivité des aléas gravitaires répertoriés sur les routes considérées entre 2008 et 2020.

En chaque point de BDG est définie la précipitation journalière extraite des radars de pluie ANTILOPE achetés à Météo-France.

A partir de ces précipitations, sont dérivés les paramètres d'entrée utilisés pour les modèles de prédiction : différents cumuls de pluie compris entre 2 (le jour j et la veille) et 45 jours. La définition des évènements pluvieux est aussi réalisée selon Melillo et al. (2015).

2.1.2 Base de données pour l'application de la prédiction

La prédiction à 3 jours du modèle de Météo-France d'Arome sont depuis 2022 utilisés pour créer l'historique de pluviométrie et de température. Les prédictions d'Arome à 24 h sont utilisées pour le calcul du niveau de vigilance à j+1.

2.2 Modèles

2.2.1 Les modèles de susceptibilité

Le modèle de susceptibilité au glissement de terrain est basé sur des études statistiques des attributs de i) topographie (pente), ii) couverture des sols (Corin Land Cover) et iii) lithologie (simplification des données du BRGM). Cette approche trouve des similitudes avec l'approche du projet européen ELSUS (European Landslide Suscpetibility : Wilde et al., 2018) et a été présentée sur un jeu de données réduit par Cadet et al, 2022. On définit tous les 100 m des routes un indice de susceptibilité (LSI : Landslide Susceptibility Index):

$$LSI(i) = \sum_{j=1}^3 \omega_j x_{ij} \quad (1)$$

Avec : i : indice du point considéré

j: indice d'un des 3 attributs (pente, lithologie ou couverture des sols)

w_j : coefficient de pondération des attributs (pente, CLC et lithologie) en fonction de leur poids dans la susceptibilité aux mouvements gravitaires. Ces coefficients sont compris entre 0 et 1 (Tableau 2).

x_{ij} : poids des différentes catégories associées à chaque attribut. Par exemple les pentes fortes ont un poids plus élevé que les pentes faibles. Ces poids sont compris entre 0 et 1.

Les coefficients de pondération des attributs sont définis à partir des coefficients de corrélation de chaque attribut avec la présence ou non d'un glissement de terrain. Le poids des catégories est calculé par le rapport des histogrammes entre les zones en glissement et les zones hors glissement.

Tableau 2 : coefficient de pondération des trois attributs utilisés pour le LSI

Attributs	Coefficient de corrélation	Coefficient normalisé = pondération
Pente sur un pixel de 20m	79	0.56 = w1
Couverture du sol (CLC 2018)	37	0.26 = w2
Géologie simplifiée	26	0.18 = w3

2.2.2 Les modèles de prédiction

L'ensemble des paramètres d'entrée ont été considéré dans un premier temps (les cumuls des précipitations de 1 à 45 jours). Une étape préliminaire a été réalisée afin de diminuer ce nombre de paramètres d'entrée. Les corrélations intra-paramètres ainsi que les facteurs d'inflation de la variance (VIF) soulignant la multi-colinéarité ont été calculés pour éliminer les liens trop forts entre les paramètres d'entrée.

D'autre part les évènements pluvieux, définis par la méthodologie de Melillo et al. (2015) ont été calculés sur l'ensemble de la période 2008-2020. Les paramètres d'entrée intensité-durée pour chaque date et pour tous les secteurs ont été définis, afin de permettre une comparaison aux méthodes classiques de seuil intensité-durée (Guzzetti et al. 2007).

De nombreux modèles de prédiction basés sur l'intelligence artificielle (IA) ont été testés: les plus proches voisins (KNN pour K-Nearest Neighbors), les machines à vecteurs de support (SVM pour Support Vector Machines), les forêts d'arbres de décision (RFM pour Random Forests) et les méthodes d'ensemble séquentielles (Boost).

La méthode KNN se base sur le principe que des points similaires sont proches les uns des autres dans l'espace des paramètres d'entrée. Elle la classe d'un nouvel exemple en regardant les classes des k voisins les plus proches et en prenant la classe majoritaire parmi eux. Facile à mettre en œuvre (pas d'apprentissage), elle est cependant sensible aux bruits. Les méthodes SVM sont des modèles de classification et de régression utilisés pour trouver un hyperplan optimal dans un espace de paramètres d'entrée pour séparer les classes. Cette méthode est bien plus robuste aux bruits, mais elle requiert un bon choix de paramétrage. La méthode RFM est une technique d'apprentissage ensembliste qui combine plusieurs arbres de décision pour améliorer la précision et la robustesse du modèle. La prédiction finale est obtenue en agrégeant les prédictions de tous les arbres. Les méthodes de Boosting sont des méthodes d'ensemble qui construisent des modèles de prédiction en séquence, en mettant l'accent sur les exemples mal classés par les modèles précédents. Nous avons opté pour un modèle de type RFM. RFM et boost sont toutes deux des méthodes donnant des résultats plus complexes à expliciter.

Différentes métriques ont été calculées sur des jeux de données test représentant environ 25 % des données. Une attention particulière a été donnée au rappel, qui caractérise le nombre d'évènements effectivement détectés par le modèle de prédiction. Le rappel donne donc la capacité d'un modèle à identifier tous les aléas gravitaires avérés. La précision, qui met l'accent sur le nombre de fausses alertes, sera aussi observée dans une moindre mesure. La précision permet d'évaluer la qualité des prédictions positives du modèle. La mesure de F-béta score, avec $\beta=2$, a été choisie afin de valoriser les valeurs élevées de rappel par rapport à celle de précision.

3 Résultats

3.1 Modèle de susceptibilité

Le projet SIGALE vise une surveillance sur l'ensemble du réseau routier, et non sur les seuls endroits ayant connu un événement par le passé. Les modèles de susceptibilité nous permettent de définir des zones homogènes en terme d'aléa.

Pour les glissements de terrain, les LSI, définis tous les 100 m, dont les valeurs sont suffisamment proches sont regroupés pour former des secteurs homogènes. Il y a 5027 secteurs susceptibles au glissement de terrain, représentés sur la Figure 2. Pour valider la pertinence de cette approche, la courbe « ROC », taux de vrai positif selon taux de faux positif, est estimée pour un échantillon de points sur la route à plus de 100 m d'un glissement et pour les 481 glissements. L'aire sous cette courbe est de 87%. Une nette amélioration est obtenue par rapport aux zones de montagne du ELSUS-v2 (Wilde et al. 2018) qui obtient 68% et à la première version des LSI sur une base de données plus restreinte qui était de 78% (Cadet et al., 2022).

3.2 Modèle de prédiction IA

3.2.1 La sélection des paramètres d'entrée

La première étape consiste à sélectionner des paramètres d'entrée indépendants entre eux et de minimiser leur nombre afin d'optimiser les calculs et le service-web qui y sera associé. Pour cela les corrélations et les VIF sont observées entre l'ensemble des paramètres.

Les dates étant potentiellement entachées d'erreur (+1 jour), on garde le cumul sur 2 jours (rain2) comme paramètre de pluie à court terme (à la place du cumul le jour j). le cumul sur 8 jours (rain8) est le premier qui est peu corrélés (coefficient inférieur à 70%) avec rain2. Rain8 étant fortement corrélé avec rain12, on peut utiliser indifféremment rain8 ou rain12. On garde rain12 comme cumul moyen terme, et on choisit donc rain45 comme cumul long terme (le premier long terme ayant une corrélation inférieure à 70% avec le cumul moyen terme). Les VIF sont tous inférieurs à 4.

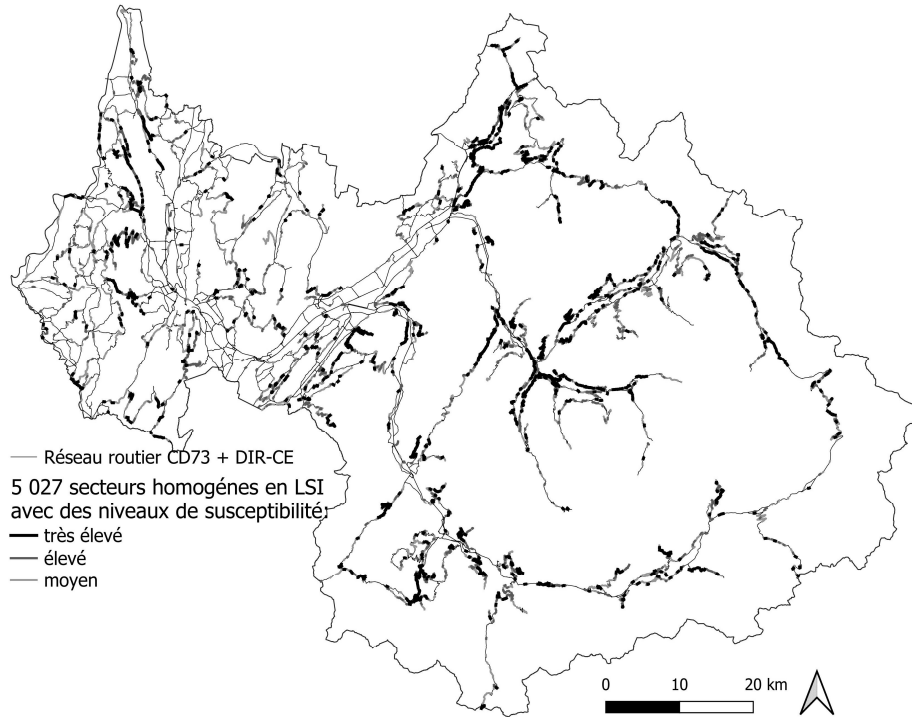


Figure 2. Répartition des secteurs homogènes en terme de susceptibilité au glissement de terrain.

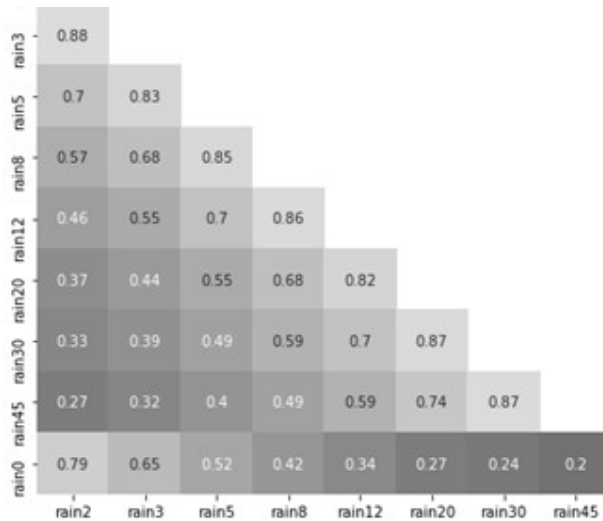


Figure 3. Coefficients de corrélation sur la base de données BDG

3.2.2 La sélection des modèles IA

Le modèle de prédiction glissement de terrain sélectionné est basé sur trois cumuls de précipitations à 2, 12 et 45 jours avant le jour considéré. Les métriques mesurées sur le jeu de test (avec un sous échantillonnage des non-événements et une méthode de validation croisée pour estimer la stabilité des résultats) sont largement améliorées avec la méthode Boost (voir tableaux suivants). De plus, cette méthode montre aussi une stabilité améliorée (écart-type plus faible).

Tableau 3 : Exemple de matrice de confusion pour l'un des sous-ensembles testés pour le modèle Boost, avec 91 glissements de terrain et 91 jours sans évènements aléatoirement choisis entre 2008 et 2020

		Réel		
		Pas d'événement	Glissement	
Prédiction	Pas d'événement	VN = 37	FN = 14	51 cas ; valeur prédictive négative : $VN/(VN+FN) = 73\%$
	Glissement	FP = 54	VP = 77	131 cas ; Précision : $VP/(VP+FP) = 59\%$
		91 cas ; Taux de faux positifs : $FP/(FP+VN) 59 \%$	91 Rappel : $VP/(VP+FN) 85 \%$	182 cas ; Exactitude : $(VP+VN)/\text{tous} = 63\%$

Tableau 4 : Métriques (pour les modèles RFM et Boost : médiane et écart-type sur les 5 sous-ensembles de la validation croisée et paramètres d'entrée : 3 cumuls)

Modèle IA ou seuil	Rappel	Exactitude	Précision	Taux de faux positifs	F-beta avec beta=2
SVM	47	34	40	80	45
KNN	56	40	45	79	53
RFM	64 ; 6	69 ; 3	73 ; 3	25 ; 4	65 ; 5
Boost	81 ; 3	63 ; 3	60 ; 2	55 ; 3	76 ; 3
Floris et al (2004)	15	9	13	98	15
Aleotti (2004)	0	0	0	100	0
Brunetti et al. (2010)	69	54	53	60	65
Ceriani et al. (1994)	4	2	4	100	4
Calcaterra et al. (2000)	32	19	25	94	30

3.2.3 Comparaison aux modèles de type seuil

Il existe de nombreux modèles de type seuil intensité-durée. L'article de Guzzetti et al. (2007) est une revue de modèles existants qui nous a permis de sélectionner des modèles les plus adaptés à notre situation : une validité des modèles pour des durées supérieures à 24h, des modèles adaptés aux glissements de terrain, dans des régions proches des Alpes pour avoir un climat similaire. Ces modèles sont représentés dans la figure suivante avec les boîtes à moustaches des évènements pluvieux associés aux glissements de terrain. Les métriques associées sont données dans le tableau précédent. Ces approches sont moins performantes que le modèle IA de type Boost.

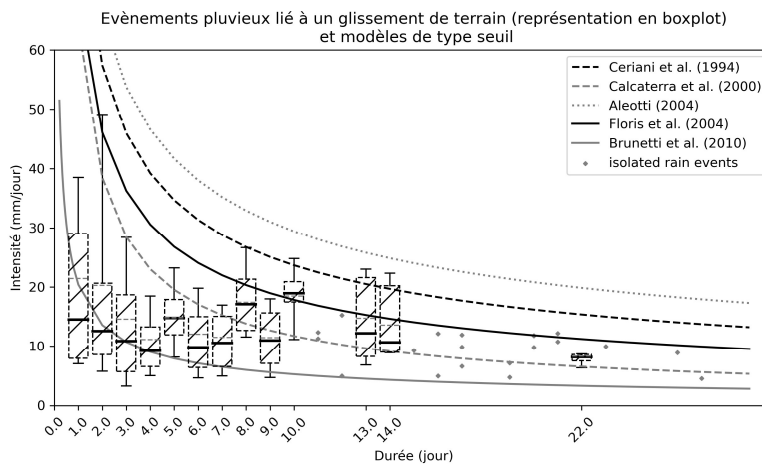


Figure 4. Représentation en boîte à moustaches (quantiles 0.1, 0.5 et 0.9 et moyenne) des évènements pluvieux liés aux glissements de terrain, comparés aux modèles intensité-durée.

3.3 Le service-web

Le prototype de service-web permet la visualisation du niveau de vigilance, combinant susceptibilité et prédiction. Ce niveau de vigilance est représenté graphiquement sur une période maximale de 14 jours (Figure 5 à gauche) et en moyenne sur la zone considérée (chiffre sur la Figure 5 en haut à gauche). La zone considérée peut être de trois niveau : a) le territoire entier (ie. Les routes), b) une zone parmi les 10 zones prioritaires définies avec le département, regroupant des vallées proches (Figure 5, à droite) et c) le secteur (tronçon de route homogène en terme d'aléa).

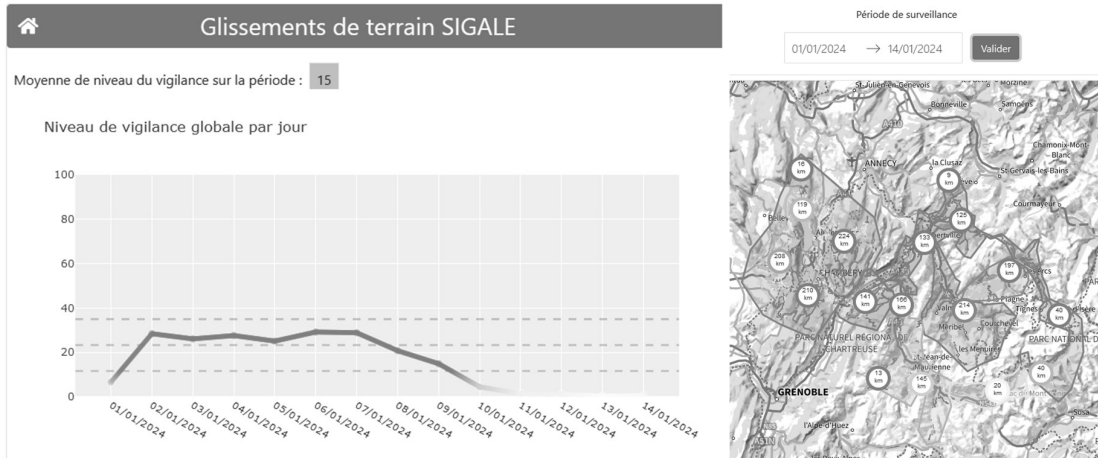


Figure 5. Prototype de service web, pour la période du 1 au 14 janvier 2024. Gauche : résultat de la vigilance pour l'ensemble des routes de la Savoie et évolution sur la période sélectionnée. Droite : zones prioritaires avec une couleur selon la vigilance moyenne

3.4 Retour d'expérience sur un cas réel

Sur un site d'étude, en 2023, on détecte 9 événements de type bloc et un événement de type éboulement rocheux d'environ 1000 m³. Ces événements ainsi que la prédiction SIGALE sur une moyenne glissante de 5 jours sont représentés sur la figure suivante. Avec un niveau d'alerte à 0.25 maintenu sur deux jours, 5 des 10 événements (dont l'éboulement principal) sont détectés.

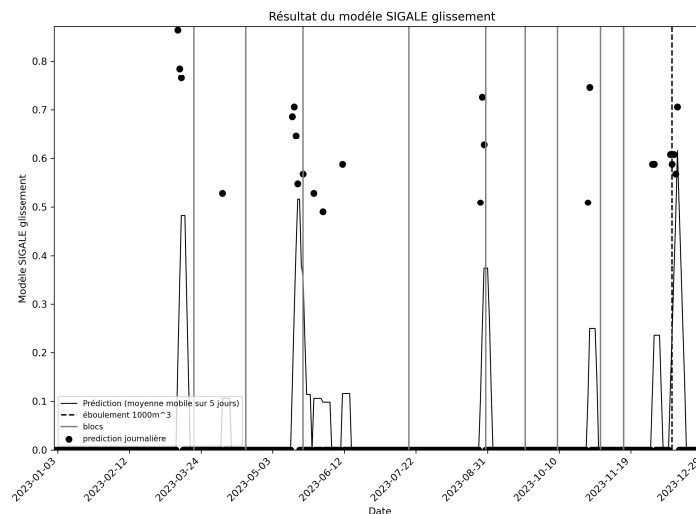


Figure 6. Résultat de la prédiction moyenne sur 5 jours au niveau du site étudié sur l'année 2023 et comparaison aux dates des événements connus

4 Conclusions

Le prototype de système de vigilance en ligne SIGALE élaboré pour anticiper les aléas gravitaires dans le département de la Savoie représente une avancée significative dans la gestion des risques naturels en montagne. Fondé sur l'intelligence artificielle, ce système intègre un modèle spatial de susceptibilité et un modèle de prédiction, s'appuyant sur une base de données quasi-exhaustive de glissements de terrain sur la période 2008-2020.

La méthodologie, axée sur la sélection judicieuse des paramètres d'entrée et l'utilisation de méthodes d'intelligence artificielle, a permis d'optimiser les modèles de prédiction des glissements de terrain. Les métriques, notamment le rappel et le F-beta score, témoignent de l'efficacité du modèle sélectionné.

Le prototype de service-web offre une vision spatiale des niveaux de vigilance, combinant les aspects de susceptibilité et de prédiction. L'interface conviviale, adaptable à différentes échelles territoriales, permet aux gestionnaires de prendre des décisions éclairées en matière de sécurité routière, offrant ainsi un outil précieux dans la gestion proactive des aléas gravitaires. Le REX sur un site instrumenté montre l'utilité de l'outil pour des actions préventives.

Enfin, les résultats encourageants obtenus grâce à ce projet soulignent l'importance de la collaboration entre les acteurs régionaux publics et privés, avec le soutien financier de la région AURA, du CD73 et de la DIR-CE, dans le développement de solutions novatrices pour la prévention des glissements de terrain.

5 Références bibliographiques

- Aleotti P (2004) A warning system for rainfall-induced shallow failures. *Eng Geol* 73: 247–265
- Brunetti MT, Peruccacci S, Rossi M, Luciani S, Valig D, Guzzetti F (2010) Rainfall thresholds for the possible occurrence of landslides in Italy. *Nat Hazards Earth Syst Sci* 10(3):447–458.
- Cadet H., Rouquet D. et Lescurier A. (2022). Gravitational hazard (landslide and rockfall) susceptibility indexes for the Savoie Département infrastructure. Conférence: JAG-2022
- Calcaterra D, Parise M, Palma B, Pelella L (2000) The influence of meteoric events in triggering shallow landslides in pyroclastic deposits of Campania, Italy. In: *Proceedings 8th International Symposium on Landslides*. Cardiff: A.A. Balkema, 1: 209–214
- Ceriani M, Lauzi S, Padovan N (1992) Rainfall and landslides in the Alpine area of Lombardia Region, central Alps, Italy. In: *Interpraevent Int. Symposium*. Bern: 2: 9–20
- Floris M, Mari M, Romeo RW, Gori U (2004) Modelling of landslide-triggering factors – A case study in the Northern Apennines, Italy. In: *Lecture Notes in Earth Sciences 104: Engineering Geology for Infrastructure Planning in Europe*, 745–753
- Guzzetti F, Peruccacci S, Rossi M and Stark CP (2007). Rainfall thresholds for the initiation of landslides in central and southern Europe; *Meteorol. Atmos. Phys.* 98 239–267.
- Guzzetti, F., Gariano, S. L., Peruccacci, S., Brunetti, M. T., Marchesini, I., Rossi, M., et al. (2020). Geographical landslide early warning systems. *Earth-Science Rev.* 200, 102973.
- Melillo, M., Brunetti, M.T., Peruccacci, S., Gariano, S.L., Guzzetti, F. (2015). An algorithm for the objective reconstruction of rainfall events responsible for landslides. *Landslides* 12, 311–320.
- Wilde, M., Gunther, A., Reichenbach, P., Malet, J. and Hervas, J. (2018). Pan-European landslide susceptibility mapping: ELSUS Version 2, *JOURNAL OF MAPS*, ISSN 1744-5647, 14 (2), 2018, p. 97-104, JRC105147.

6 Remerciements



La Région
Auvergne-Rhône-Alpes

Le projet SIGALE a été partiellement financé par la région AURA, le CD73 et la DIR-CE.