


Utilisation de l'apprentissage profond pour la détection de dangers naturels

Contexte

Les glissements de terrains sont l'une des principales menaces naturelles en Suisse, qui compte près de 6% de sa surface en zones instables. La construction d'ouvrages de protection n'est pas systématiquement nécessaire, parfois la mise en place d'un réseau de surveillance suffit à atténuer les risques. Ainsi, différentes techniques de contrôle sont mises en place pour le suivi des déplacements telles que des capteurs sur le site, des caméras de surveillance, des lasers scanners, des mesures radar par interférométrie (SAR) ainsi que des techniques de suivi par GPS.

Objectifs

Face au volume d'informations produites, les méthodes d'apprentissage profond ou *deep learning* offrent un potentiel pour le traitement automatisé des données récoltées ainsi que pour la prédiction. Notre projet a pour but d'évaluer les potentiels et les limitations de l'apprentissage profond dans la surveillance et la prédiction des glissements de terrains. Pour ce faire, deux approches ont été choisies, l'une ciblant des photographies et pour l'autre, des données de déplacements. Finalement, les outils utilisés à travers ce travail veulent faciliter la tâche du géologue dans l'analyse des risques et, éventuellement, la mise en place d'un alarme préventive grâce à la surveillance automatique.




Zone de glissement de terrain de Moosfluh, glacier d'Aletsch, Google Earth


Introduction au Deep Learning

L'apprentissage profond regroupe différentes méthodes d'apprentissage automatique grâce à des réseaux de neurones. Cette technologie impressionne par sa capacité à mémoriser des motifs qui lui sont fournis à l'entraînement, et les reconnaître ensuite sur un nouveau jeu de données.


Pour le tri des images, un réseau de classification appelé Alex Net est employé. Les images données à l'entrée traversent plusieurs filtres de convolution, où certaines de leur caractéristiques sont détectées, et en fonction desquelles une classe est attribuée à l'image.



Pour les données temporelles de déplacements, un autre type d'algorithme a été employé: l'algorithme LSTM pour "Long Short Term Memory", un type de réseau de neurones récurrent capable d'être entraîné avec des données temporelles pour prédire le comportement futur à partir de celui du passé.



Méthode 1 : Analyse d'images



Obtention et présélection des images

Près de 400 images ont été classifiées manuellement pour éliminer les cas de mauvais contraste ou de mauvaise visibilité due à la météo. Ensuite, un algorithme de Deep Learning a été entraîné et a trié le reste de nos images avec une précision de 98%.

Retrait des images inutilisables




Les images ont été classées visuellement par paires en fonction des changements observés: écoulements d'eau, chutes de bloc ou calme. Cette étape chronophage est inévitable pour attribuer les labels aux images.

Classification manuelle des changements observés

La luminosité a été améliorée par association d'histogramme. Cette méthode décale la distribution d'intensité des pixels d'une image pour qu'elle corresponde à celle d'une image de référence. Cela réduit le bruit lors de la création de la différence d'image à l'étape suivante.

Correction de luminosité



Ce processus met en évidence les zones qui ont changé entre deux images successives. La différence d'image est créée par soustraction de la valeur des pixels de chaque image. Les zones où un changement a été observé obtiennent des valeurs élevées (en blanc), tandis que les zones noires indiquent des zones calmes.

Création de la différence d'image

Cette dernière étape permet la détection automatique de changements grâce à un algorithme de Deep Learning qui classe les différences d'images. Après entraînement, l'algorithme détecte les glissements de terrain, les chutes de pierres ou les écoulements d'eau avec une précision de 90%.


Classification avec Deep Learning

True class \ Predicted class	calm	volume
calm	39	3
volume	4	24

Cette matrice de confusion permet de comparer la classe réelle et la classe prédite par l'algorithme. Les images classées correctement se trouvent sur la diagonale principale. Volume indique qu'un changement est présent, alors que calme non.

Méthode 2 : Analyse des données des extensomètres

- Le but de cette partie est d'utiliser l'algorithme LSTM pour prédire le comportement des données des extensomètres sur 3 sites : La Sionne, La Suche et Évolène. Contrairement aux images, les séries temporelles peuvent être directement données à l'algorithme LSTM avec peu ou aucun prétraitement.
- Lors de l'entraînement, 90% données sont utilisées et le 10% restant sert à vérifier la qualité des prédictions. A chaque itération, le LSTM ajuste ses paramètres et réduit l'erreur de prédiction.
- Différents paramètres ont été testés durant les simulations comme le nombre de "hidden units" qui correspond à la quantité d'information retenu à chaque étape, ainsi que le nombre d'itérations. Les simulations ont nécessité l'utilisation des unités de calculs de haute performance sur le cluster de EPFL, Deneb 1.



Résultats

Pour la classification des images, le résultat final de précision de 90% semble relativement bon, mais il n'est pas suffisant pour garantir la sécurité dans un cas réel de glissement de terrain. Le principal problème rencontré est bien connu dans le domaine d'analyse d'image : la mauvaise correction de la luminosité. L'association d'histogramme applique une correction globale à l'image alors qu'une correction locale serait plus appropriée pour éliminer les petites variations. Cette correction imparfaite amène du bruit lors de la création de la différence d'image et rend le travail de classification de l'algorithme plus difficile.

Pour les données temporelles, l'algorithme est capable de prédire des données cycliques avec du bruit, et le lissage des mesures ne donne pas forcément de meilleurs résultats, comme on le voit avec La Suche. De plus, nous pouvons voir pour La Sionne que de petits changements sur les paramètres peuvent avoir un impact considérable sur les prédictions. Pour les données avec une croissance exponentielle, tel que lors des chutes de bloc à Evolène, trouver un algorithme qui peut arriver à de bonnes prédictions s'est révélé particulièrement difficile.

Discussion

D'autres méthodes d'analyse d'images pourraient être appliquées telle que le travail par ratio de texture, par analyse des principales composantes (PCA), ou par transformation en vaguelettes. Certains algorithmes comme les CNN-LSTM ou les Deep Belief Network, plus complexes, n'ont pas pu être mis en place dans le cadre de ce projet, mais il serait intéressant de comparer leurs résultats, étant donné que la correction de luminosité fait partie intégrante de l'algorithme, et n'est plus une étape de prétraitement.

Concernant les données des extensomètres, le principal défi réside en la prédiction des événements soudains, comme à Evolène. L'entraînement avec des données concaténées pourrait encore être explorée. De plus, il serait désirable d'ajouter les mesures de température et la pluie comme variables prédictives supplémentaires et de voir si le fait de les incorporer dans le modèle améliore les prédictions. Enfin, un autre problème concerne la longueur de la mémoire de l'algorithme, qui n'est pas explicite dans Matlab. Travailler avec Python permettrait plus de libertés à ce niveau.

Conclusion

Le potentiel du Deep Learning pour la prédiction des glissements de terrain est large. Concernant l'analyse d'images, certaines limites pratiques apparaissent comme la disponibilité des données et la classification manuelle des images. Notre méthode est aussi limitée techniquement par la correction de la luminosité. Néanmoins, l'utilisation d'autres algorithmes apparaît comme une alternative prometteuse pour surmonter ce dernier problème.

Concernant les données des extensomètres, notre méthode présente l'avantage de nécessiter peu de prétraitement. En outre, à l'opposé des images, les données des extensomètres sont largement disponibles en Suisse. De plus, le LSTM a prouvé ses capacités de prédictions sur des données cycliques avec du bruit. La prochaine étape serait d'affiner la prédiction des événements non-cycliques. Dans cette perspective, le potentiel du LSTM pour la surveillance automatique de sites instables est énorme. Pour ces raisons, il serait judicieux de se focaliser sur ce type de données dans des futures recherches.