

APPLICATION DU MACHINE LEARNING A LA SURVEILLANCE MICROSISMIQUE D'OPERATIONS INDUSTRIELLES DU SOUS-SOL

MACHINE LEARNING APPLICATION TO THE MICROSEISMIC MONITORING OF UNDERGROUND INDUSTRIAL SITES

Jean-Bernard KAZMIERCZAK¹, Armand LIZEUR², Isabelle CONTRUCCI², Pascal BIGARRE¹

¹ *Ineris – Parc Technologique Alata – BP 2 – 60550 Verneuil-en-Halatte, France*

² *Ineris - Mines Nancy - Campus ARTEM - 92 rue du Sergent Blandan - BP 14234 - 54042 NANCY Cedex, France*

RÉSUMÉ – Dans le contexte de la surveillance microsismique d'exploitations industrielles du sous-sol, la capacité de trois types de réseaux neuronaux (CNN, Inception et LSTM) de Machine Learning a été testée pour identifier en quasi temps réel l'origine de signaux microsismiques provenant d'un réseau de surveillance d'anciens chantiers profonds à l'échelle du bassin minier de Gardanne, en France.

ABSTRACT – In the context of microseismic monitoring of underground industrial exploitations, we are testing the capabilities of three types of neural networks (CNN, Inception and LSTM) of Machine Learning to identify in near to real-time the origin of microseismic waveforms recorded in the frame of the monitoring of ancient deep mining works at the scale of the coal basin of Gardanne, France.

1. Introduction

La surveillance microsismique est une technique qui consiste à détecter et enregistrer les ondes émises lors de la fracturation et de la fissuration des massifs rocheux. Elle est classiquement utilisée pour la prévention des risques d'instabilité lors de l'exploitation industrielle du sous-sol comme dans le cas de l'extraction minière, des stockages géologiques ou encore de la géothermie profonde (Contrucci & Klein, 2017). En effet, ces activités sont génératrices de redistributions importantes de contraintes dans le sous-sol qui peuvent, dans certaines conditions, générer des instabilités brutales. La surveillance microsismique est un outil indispensable pour suivre le comportement de l'encaissant in situ, classifier les zones exploitées en termes d'aléa et risques, et assurer la sécurité des personnels et de l'environnement.

En France, cet outil a été choisi pour la gestion de l'après mine dans certaines sites et territoires où l'exploitation minière a été particulièrement importante et a laissé des zones fragiles susceptibles de présenter des instabilités bien au-delà de l'arrêt de l'exploitation (Contrucci et al., 2010 ; Bigarré et al., 2011). C'est le cas par exemple de l'ancien bassin ferrifère lorrain, où la fin de l'exploitation dans les années 90, a été marquée par plusieurs effondrements (Didier, 2007) ou affaissements miniers (Contrucci et al. 2019). L'ancien bassin houiller de Provence, qui montre encore aujourd'hui une sismicité résiduelle avec des crises ressenties par la population alors que l'exploitation a été arrêtée depuis 2003 (Kinscher et al., 2018 ; Matrullo et al., 2015).

Cette surveillance microsismique est habituellement réalisée via l'enregistrement et l'analyse de signaux provenant de stations de mesures de surface ou en forages et implantées dans la zone d'intérêt à surveiller (Contrucci et al., 2013). Dans le cas spécifique de la surveillance d'anciennes mines, les signaux enregistrés, sont synonymes de l'occurrence de désordres sporadiques et diffus à l'échelle de la mine, mais ils peuvent également avoir pour origine des activités anthropiques de surface (travaux urbains, bruits

parasites divers, tirs de carrière) ou encore une origine naturelle (séismes naturels, orages et surtensions).

Les signaux, issus de ces différents phénomènes, présentent des similarités et sont traités automatiquement en quasi temps réel, activant le cas échéant une alarme vers un opérateur spécialiste dans un délai court, pour en déterminer l'origine (phases successives de qualification et validation). Ainsi, cette étape permet de définir si l'occurrence d'une séquence de données validées peut être le précurseur d'un évènement redouté pouvant avoir des conséquences en surface, si elle est simplement liée à l'activité anthropique de surface, voire à une combinaison des deux. L'automatisation de la phase de qualification des données en quasi-temps réel de la manière la plus automatisée et fiable à la fois est donc d'un intérêt évident.

Les méthodes d'apprentissage (Machine Learning) associées à l'Intelligence Artificielle sont bien adaptées pour réaliser de la classification automatique d'informations. L'étude menée et décrite dans cet article visait à tester trois types de réseaux neuronaux (CNN, Inception et LSTM) pour évaluer leur capacité à prédire, sans intervention humaine, 24h/24, l'origine des signaux microsismiques d'un réseau de stations de surface couvrant plusieurs sites répartis sur un plus vaste territoire. Le cas de l'ancien bassin minier de Gardanne (Provence), objet d'une microsismicité résiduelle de long terme, est utilisé pour illustrer cette application, car il est représentatif de la surveillance d'opérations industrielles en milieu souterrain sismogéniques.

2. La surveillance microsismique – Exemple du bassin houiller de Gardanne (Provence)

2.1. Contexte et objectifs

L'activité minière en France a laissé de nombreux vides souterrains qui peuvent à long terme provoquer ou non des affaissements ou des effondrements dans des zones devenues aujourd'hui à forte densité de population et de bâtis (Figure 1). Pour gérer ces risques, définis a priori comme incertains, une gestion par la surveillance microsismique a été mise en place dans certaines zones sous minées et à forts enjeux situées en Lorraine et dans les Bouches du Rhône.

Cette surveillance microsismique est réalisée à partir de stations isolées en forage placés à l'aplomb ou autour des zones à surveiller. Si les vides miniers sont abandonnés et les sources microsismiques nécessairement liées à des désordres géotechniques et instabilités locales et diffuses, l'activité anthropique de surface reste une source d'artefacts qui reste l'objet d'une attention constante.

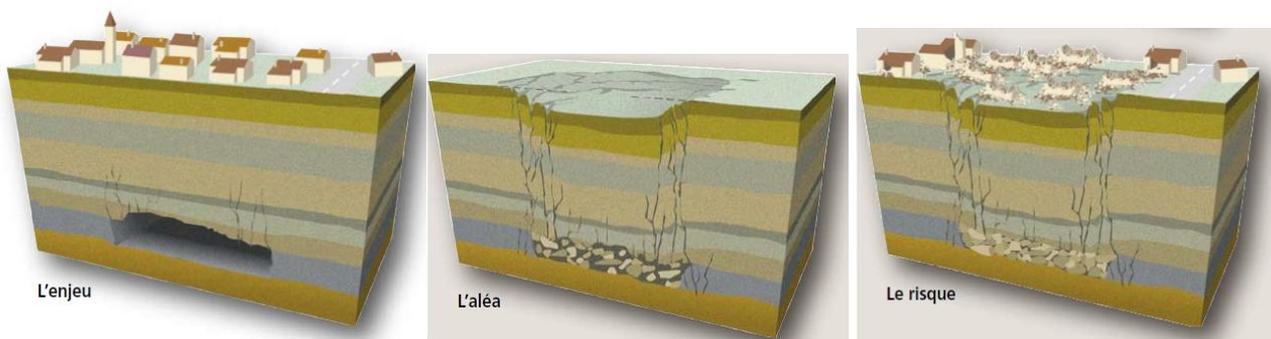


Figure 1. Illustration de l'enjeu, de l'aléa et du risque, croisement des deux notions.

2.2. Dispositif de surveillance

Le dispositif de surveillance microsismique, déployé en Provence (Figure 2), est composé de 5 réseaux de mesure constitués chacun par une antenne verticale en forage, intégrant 3 à 4 capteurs de manière à filtrer efficacement les bruits de surface (Figure 3). Tous comportent une sonde trois-composantes profonde, implantée à plus de 100 m de profondeur, la plus profonde étant à 215 m, et donc bien isolée des bruits anthropiques de surface.

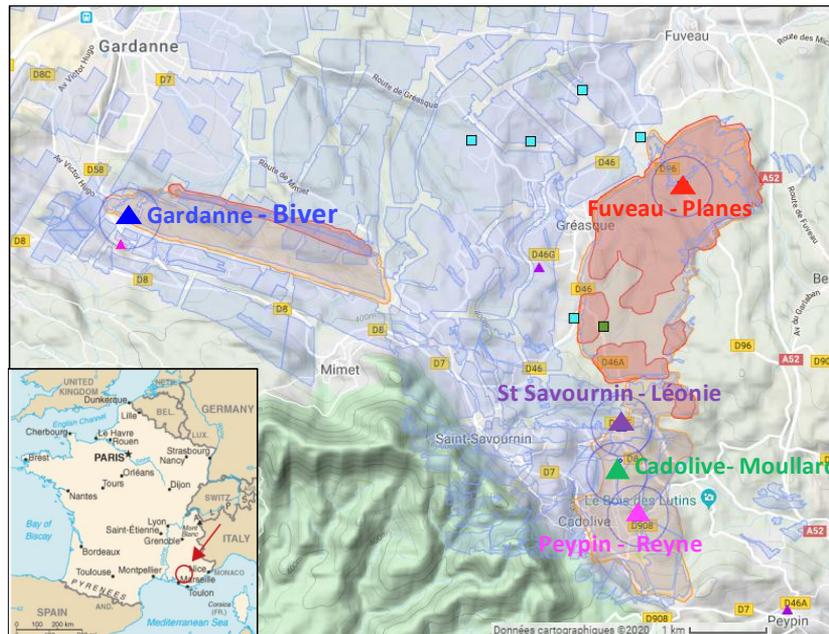


Figure 2 : implantation des réseaux de surveillance microsismique de l'ancien bassin houiller de Gardanne (Provence).

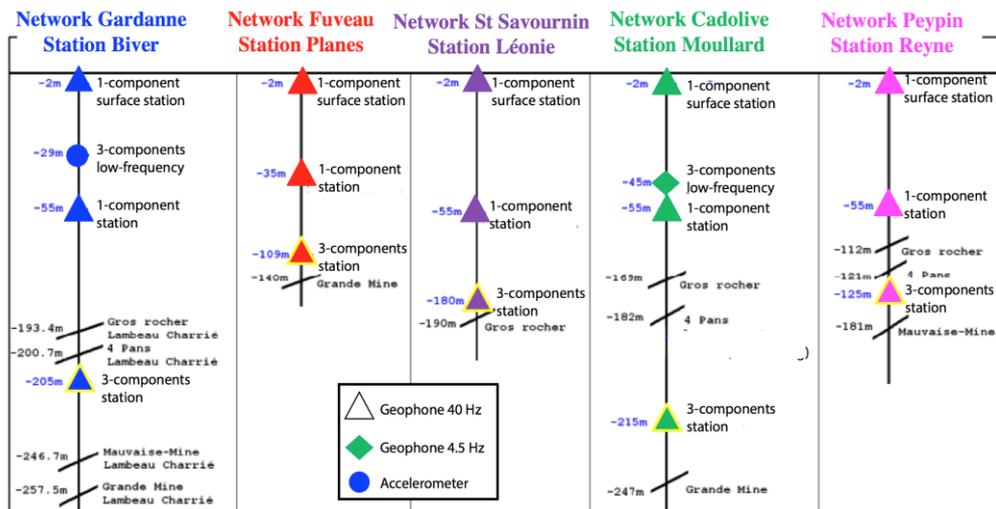


Figure 3. Constitution des réseaux de surveillance microsismique de Gardanne en Provence.

Dans cette région, l'exploitation minière s'est arrêtée en 2003. Ensuite, les travaux miniers ont été progressivement enoyés. Depuis 2008, date à laquelle le réseau de surveillance microsismique a été installé, près de 3 000 événements ont été détectés et plusieurs crises microsismiques (Figure 4) ont été enregistrées en 2012, 2014 et 2017 avec de nombreux événements ressentis par la population avec une magnitude locale de l'ordre de $M_l \approx 2,5$ (magnitude du moment $M_w \sim 1,8$) (Kinscher et al., 2017; Matrullo et al., 2015; Contrucci et al., 2013).

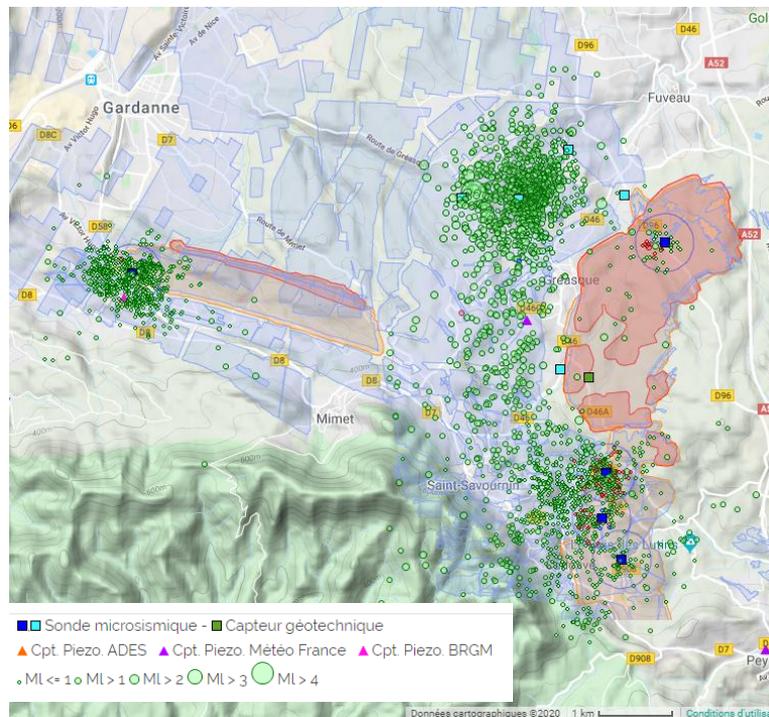


Figure 4. Carte de localisation en plan des événements microsismiques enregistrés entre 2008 et 2019

2.3. Principe de la surveillance

Le principe de la surveillance en quasi temps-réel opérée sur les zones à risque est le suivant : les signaux enregistrés sur les sites sont transmis par liaison VPN sur l'infrastructure de gestion centralisée. Le traitement automatique à réception consiste à calculer différents paramètres à partir du signal détecté : amplitudes, localisation, magnitude, etc. Sitôt les données et résultats mis en base, l'interface web de surveillance e.cenaris est mise à jour en quasi temps réel. Si les critères d'alarme, préalablement définis, sont remplis, une alarme automatique est aussi envoyée à un opérateur de permanence pour une nouvelle qualification des données et des résultats de traitement. La disqualification éventuelle des données et de l'alarme intervient de manière récurrente compte tenu du nombre significatif d'artefacts vibratoires susceptibles de toucher les stations.

3. Application du machine learning à la surveillance microsismique

3.1. Introduction

L'Intelligence Artificielle (IA), domaine s'appuyant notamment sur le Machine Learning, recouvre de nombreuses notions ou techniques dont on ne retiendra dans cet article que la notion qui consiste en un programme capable de traiter de larges volumes de données sous formes (de textes, d'images ou) de valeurs numériques et d'apprendre de cette base de connaissances à classer des données ou par régression, prévoir des événements ou des grandeurs (Aurélien Géron, 2017).

L'IA s'insère aujourd'hui dans tous les domaines socio-économiques tels que l'industrie (maintenance prédictive, aide à la décision), la santé (imagerie médicale, aide au diagnostic), les transports (aide à la conduite), le marketing (suggestions d'achats, publicités ciblées), etc.

Plusieurs acteurs majeurs du domaine des hautes technologies se sont engagés dans le développement et la mise à disposition d'outils permettant d'utiliser l'intelligence artificielle. Bien que cet outil ne soit pas encore complètement stabilisé, la solution technique que nous avons choisi d'utiliser s'appuie sur Tensorflow de Google et d'autres bibliothèques mathématiques (Scikit-learn, Numpy, Pandas, Keras, etc), notamment parce qu'elle est sous Licence Apache ; qu'il est possible d'exécuter, en local ou dans le cloud, les calculs sur CPU et GPU et qu'elle ne nécessite pas de transférer les jeux de données d'entrée vers un tiers.

3.2. Objectifs du test d'application

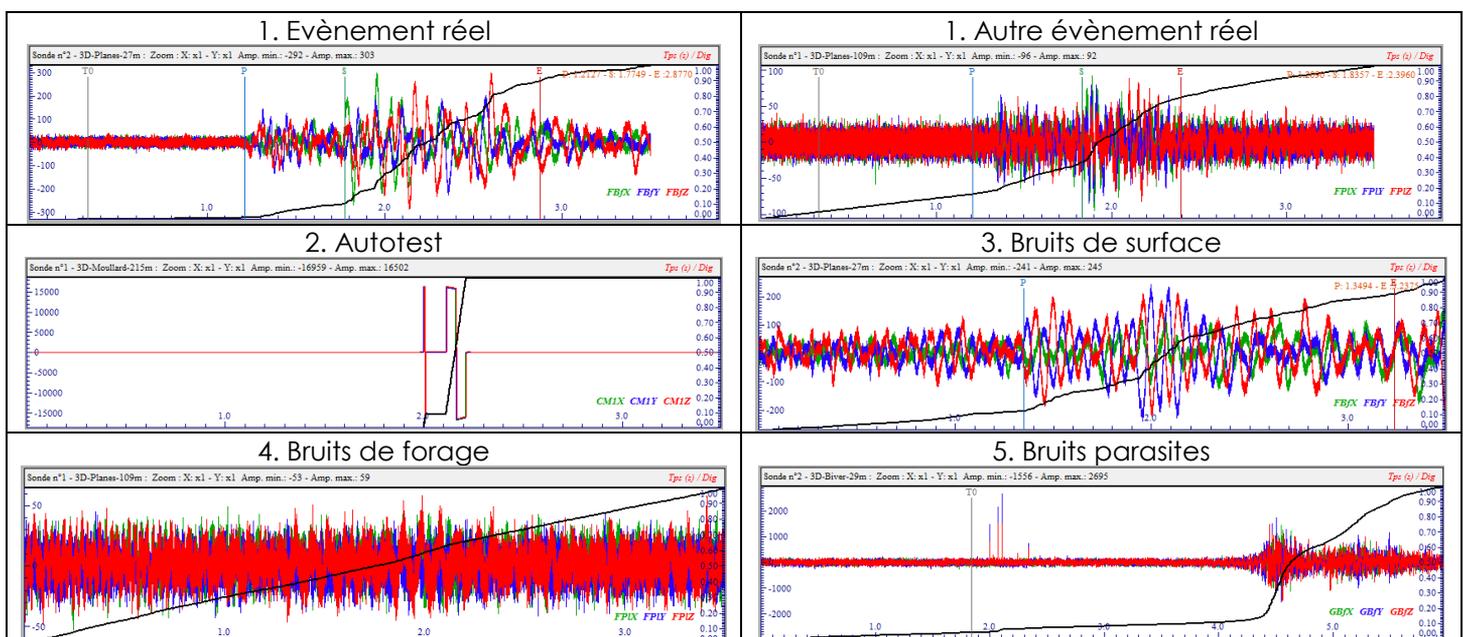
Il s'agit donc d'évaluer la capacité de plusieurs types de réseaux neuronaux à prédire la nature d'un signal microsismique parmi 7 types de signaux différents (dont un seul type correspond à un désordre qui se serait produit en souterrain). Pour ce faire, nous allons nous appuyer sur une base de données de mesures enregistrées pour une station de surveillance située en Provence.

3.3. Contenu du jeu de données utilisés pour l'apprentissage et la validation

Le jeu de données utilisé pour les opérations d'Apprentissage et de Validation (Train et Test) contient 1200 (lignes) « signaux » enregistrés à des dates diverses. Chaque signal est constitué d'un échantillonnage de 2048 valeurs (temporelles) sur 5 voies d'enregistrement.

Les 1200 signaux sont répartis selon 7 types différents (voir des exemples en Figure 5) : 309 sont des évènements réels, 298 des autotests, 303 des bruits de surface, 52 des bruits de forage, 46 des parasites, 38 des tirs de carrière et 154 des séismes naturels. Il existe donc 7 étiquettes pour ce problème.

Les matrices d'apprentissage et de validation ont été construites de la manière suivante : Pour chaque voie (5 voies), on considère le signal brut (2048 valeurs) et ses 3 dérivées successives, ce qui fait que chaque ligne de la matrice contient $2048 \times 4 \times 5 = 40\,960$ valeurs. Finalement, la matrice globale pèse environ 1 Go.



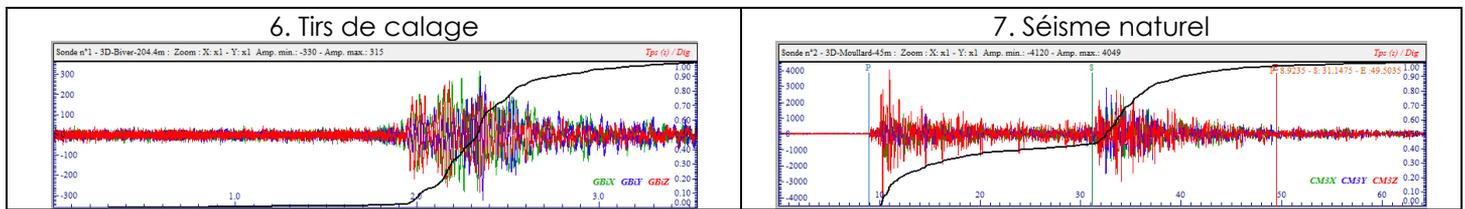


Figure 5. Exemple d'illustration des 7 types de signaux à classer.

3.4. Méthodologie de résolution retenue pour l'application du Machine Learning à la surveillance microsismique

De nombreux travaux ont été menés par différents auteurs (Jorge et al, 2013) sur le jeu de données « Human Activity Recognition Using Smartphones Dataset ». Compte tenu de la grande similarité avec le problème qui nous intéresse ici, nous nous appuyons fortement sur ces travaux pour définir la méthodologie de classification pour nos signaux microsismiques.

De manière assez classique, le problème est résolu de la manière suivante :

1. Contrôle de la qualité et mise en forme des données sous un format « exploitable » par les différents outils mathématiques utilisés ;
2. Répartition du jeu de données en deux familles (Train et Test) – deux répartition ont été testées : 70%/30% et 50%/50% ;
3. Chargement des données Train par le modèle et découpage en Entraînement et Validation ;
4. Echantillonnage et mélange aléatoire du jeu de données ;
5. Création du réseau neuronal (3 types ont été testés) ;
6. Lancement des calculs et évaluation de la performance du réseau (Perte et précision) ;
7. Test des performances du réseau sur le jeu de données de Test.

Les différents types de réseaux testés ici sont les suivants :

- Réseau de neurones CNN à convolution 1D avec plusieurs couches (1 à 10 couches testées) ;
- Réseau de type Inception (CNN multiples et profonds) ;
- Réseau de type LSTM (Long-Short-Term Memory Networks).

Ces réseaux utilisent des assemblages de « modules » mathématiques de base (ex : Réseau convolutif 1D, Maxpool, ReLU, etc) (Burakhimmetoglu, 2017). L'enjeu principal est de déterminer quel est le meilleur assemblage de modules pour le problème à traiter. Il faut également retenir que chaque réseau s'appuie sur un certain nombre d'hyperparamètres qu'il convient d'optimiser afin d'obtenir le meilleur résultat possible.

L'ensemble de ces éléments nécessitent, de ce fait, de procéder à des calculs paramétriques afin d'optimiser chacun des réseaux.

Il est à noter que 2 calculs « identiques » ne produisent pas strictement le même résultat. Cela peut paraître surprenant mais les matrices d'apprentissage et de validation sont « sous-échantillonnées et mélangées » avant chaque introduction dans le réseau neuronal. Aussi, l'apprentissage est à chaque fois « différent ». Il est donc nécessaire de lancer plusieurs fois chaque modèle pour disposer d'une évaluation plus fine de ses performances.

3.5. Performance des différents réseaux

Le Tableau 1 regroupe l'ensemble des résultats obtenus pour les différents réseaux neuronaux testés. Nous n'avons reporté que les résultats correspondant aux variations des réseaux eux-mêmes, en éliminant tous les cas de calculs paramétriques liés à l'optimisation des hyperparamètres. Nous avons cependant fait figurer les résultats des tests réalisés sur la quantité ou la répartition des données d'entrée, à savoir :

- Utilisation de 100% du jeu de données d'entrée contre uniquement les 70 premiers pourcents de chaque classe ;
- Ratio de données d'entrée dans les matrices Train/Test : 70%/30% et 50%/50%, avec 100% du jeu de données.

Retenons par ailleurs qu'il a été nécessaire d'ajuster 4 hyperparamètres pour les réseaux à base de CNN, et d'Inception et 6 pour les réseaux de type LSTM, ce qui constitue en soi un volume de travail non négligeable. A noter que 2 hyperparamètres supplémentaires sont imposés, il s'agit du nombre de canaux (5 voies d'enregistrement) et du nombre de classes (ici égal à 7).

Les trois principaux résultats à retenir des différents tests réalisés sont que :

1. Le réseau de type CNN à 3 couches présente la meilleure précision moyenne (95%) pour la classification mais sa valeur maximale n'est que de 97%.
2. Les réseaux CNN à 6 et 8 couches peuvent atteindre des précisions de 98 et 99% mais leurs précisions sont « en moyenne » assez mauvaises (71 et 65% respectivement) !
3. Les résultats obtenus par les réseaux les plus performants sont assez encourageants (>95%) mais il faut retenir que chaque pourcent compte car passer de 95% à 97% améliore en fait de 40% le résultat !

Tableau 1. Synthèse des performances des différents types de réseaux neuronaux

Type de réseau	Prop des données brutes utilisées	Précis. calcul	Moyenne	Max				
CNN 1 couche	70	89,0%	86,0%	83,5%	90,5%	81,0%	86,0%	90,5%
CNN 2 couches	70	92,0%	95,5%	92,0%	91,5%	92,0%	92,6%	95,5%
CNN 3 couches	70	96,0%	96,5%	94,5%	97,0%	91,0%	95,0%	97,0%
CNN 4 couches	70	89,0%	90,0%	87,5%	95,5%	90,5%	90,5%	95,5%
CNN 6 couches	70	65,5%	54,5%	98,0%	85,0%	56,0%	71,8%	98,0%
CNN 8 couches	70	99,0%	57,5%	43,0%	55,0%	68,0%	64,5%	99,0%
CNN 4 couches	100	77,3%					77,3%	77,3%
CNN 2 couches	100	90,7%	85,7%	92,3%			89,6%	92,3%
Inception	70	93,0%	91,0%	92,5%	95,5%	96,5%	93,7%	96,5%
Inception	100	54,0%	57,0%				55,5%	57,0%
LSTM 1 couche	70	44,0%					44,0%	44,0%
LSTM 3 couches	70	77,0%					77,0%	77,0%

4. Conclusion et Perspectives

Les travaux réalisés dans cette étude de faisabilité montrent que le Machine Learning est en mesure de prédire correctement la nature d'un signal microsismique parmi 7 types de signaux différents avec plus de 95% de chance de succès.

Certes, la phase d'apprentissage du réseau neuronal doit être réitérée pour chaque nouveau site de surveillance mais celle-ci ne nécessite que des moyens humains et matériels limités, dès lors que le meilleur modèle a été identifié et que ses hyperparamètres sont optimisés.

Cet outil pourrait ainsi être considéré à l'avenir comme une aide précieuse à la surveillance opérationnelle. Une phase de comparaison entre la classification automatique du réseau neuronal et les prédictions de l'expert va être menée en 2020 sur l'ensemble des nouveaux signaux enregistrés pour ce site. Si les prédictions sont à la hauteur des attentes, cet outil pourrait être intégré dans le dispositif Sytmis de surveillance « opérationnelle » du centre e.cenaris.

D'autres applications sont également en cours de développement, telles que la géolocalisation 3D automatique de la source des signaux ou l'anticipation des événements (temporellement et en positionnement relatif).

5. Références bibliographiques

- Bigarré, P., M. Bennani, I. Contrucci, E. Klein, H. Baroudi, R. Hadadou, I. Vuidart, and J. P. Josien (2011), Microseismic monitoring strategy as a key component of post-mining risk management: review and feedback experience on the past decade, paper presented at 12th ISRM International Congress on Rock Mechanics, "Harmonizing Rock Mechanics and the Environment", Beijing, China, 18 - 21 October 2011.
- Burakhimmetoglu (2017). Time series classification with Tensorflow, on <https://burakhimmetoglu.com/2017/08/22/time-series-classification-with-tensorflow/>
- Contrucci, I., M. Bennani, P. Bigarré, and P. Dominique (2013), Activité microsismique et caractérisation de la détectabilité des réseaux de surveillance du bassin houiller de Gardanne, paper presented at AGAP, Nancy.
- Contrucci, I., E. Klein, P. Bigarré, A. Lizeur, A. Lomax, and M. Bennani (2010), Management of Post-mining Large-scale Ground Failures: Blast Swarms Field Experiment for Calibration of Permanent Microseismic Early-warning Systems, *Pure and Applied Geophysics*, 167(1-2), 43-62.
- Contrucci, I. et Klein, E. (2017), Etat des connaissances concernant les aléas et les risques liés à la sismicité anthropique, [rapport INERIS DRS-17-149681-07390D](http://rapport.ineris.fr/DRS-17-149681-07390D).
- Contrucci, I., C. Balland, J. Kinscher, M. Bennani, P. Bigarre, and P. Bernard (2019), Aseismic Mining Subsidence in an Abandoned Mine: Influence Factors and Consequences for Post-Mining Risk Management, *Pure and Applied Geophysics*, 176(2), 801-825.
- De Santis, F., I. Contrucci, J. Kinscher, P. Bernard, V. Renaud, and Y. Gunzburger (2019), Impact of Geological Heterogeneities on Induced-Seismicity in a Deep Sublevel Stopping Mine, *Pure and Applied Geophysics*, 176(2), 697-717.
- Didier, C. (2007), La politique française de prévention des risques liés à l'après-mine, *Réalités Industrielles* 86-97.
- Géron A. (2017). *Machine Learning avec TensorFlow/ avec Scikit-Learn – Mise en œuvre et cas concrets* – Edition Dunod.
- Jorge L. Reyes-Ortiz, Alessandro Ghio, Luca Oneto, Davide Anguita and Xavier Parra. (2013). Human Activity Recognition on Smartphones Using a Multiclass Hardware-Friendly Support Vector Machine. International Workshop on Ambient Assisted Living
- Kinscher, J., D. Namjesnik, I. Contrucci, P. Dominique, and E. Klein (2018), Relevance of Seismic Risk Assessment in Abandoned Mining Districts : the Case of the Gardanne Coal Mine, Provence, France, paper presented at Proceedings of the 12th International conference on mine closure. Freiberg, Bergakademie Freiberg.
- Matrullo, E., I. Contrucci, P. Dominique, M. Bennani, H. Aochi, J. Kinsher, P. Bernard, and P. Bigarré (2015), Analysis and Interpretation of Induced Micro-seismicity by Flooding of the Gardanne Coal Basin (Provence – Southern France), in 77th EAGE Conference & Exhibition 2015, edited, Madrid, Spain.
- Tensorflow. <https://www.tensorflow.org/>