

## APPLICATION DE L'INTELLIGENCE ARTIFICIELLE A LA CARTOGRAPHIE GÉOLOGIQUE DU DISTRICT DE KENIEBA, MALI

Awa KONE<sup>1\*</sup>, Fransisco Kouadio KONAN<sup>2,3,4,5</sup>,  
Hamadoun Bokar MAIGA<sup>1</sup>, Ibrahima DAOU<sup>6</sup>  
et Mamadou Lamine BOUARE<sup>7</sup>

<sup>1</sup> *École Normale d'Enseignement Technique et Professionnel (ENETP),  
Département de Génie Mécanique, Energie et Mine, Laboratoire de Mine et  
Géologie, Bamako, Mali*

<sup>2</sup> *Ecole Normale Supérieure (ENS) Abidjan, Département des Sciences et  
Technologies, Laboratoire des Sciences Physiques Fondamentales et  
Appliquées, Equipe de recherche : Sol-gel, Matériaux, Energies  
Renouvelables et Environnement, 08 BP 10 Abidjan 08, Côte d'Ivoire*

<sup>3</sup> *Laboratoire de Mathématiques et Sciences Physiques Appliquées aux  
Sciences de l'Ingénieur (MSPASI), FSTM, Université Hassan II de  
Casablanca (UH2C), BP 146 Mohammedia 20650, Morocco*

<sup>4</sup> *Université Nangui Abrogoua, Laboratoire d'Energie Solaire et de  
Nanotechnologie (LESN) – IREN (Institut de Recherches sur les Energies  
Nouvelles), 02 BP 801 Abidjan 02, Côte d'Ivoire*

<sup>5</sup> *Unité Mixte de Recherche et d'Innovation en Sciences et Techniques de  
l'Ingénieur (UMRI-STI), Institut National Polytechnique Houphouët-Boigny  
(INP-HB), BP 1093 Yamoussoukro, Côte d'Ivoire*

<sup>6</sup> *Ecole Nationale d'Ingénieurs Abderrahmane Baba Touré (ENI-ABT),  
Laboratoire de recherche eau/ environnement, BP 242 Bamako, Mali*

<sup>7</sup> *Institut Polytechnique Rural de Formation et de Recherche Appliquée de  
Katibougou (IPR/IFRA), BP 224, Mali*

(reçu le 19 Janvier 2026; accepté le 11 Mai 2026)

\* Correspondance, e-mail : [awakon444@gmail.com](mailto:awakon444@gmail.com)

### RÉSUMÉ

Cette étude vise à évaluer l'apport des méthodes d'intelligence artificielle (IA) dans l'amélioration de la cartographie géologique d'une région caractérisée par une forte complexité litho-structurale. Les approches traditionnelles présentent certaines limites, notamment la subjectivité liée à l'interprétation visuelle des données et les difficultés d'accès à certaines zones de terrain, ce qui peut réduire la précision et l'homogénéité des cartes géologiques. Dans ce contexte,

L'apprentissage automatique constitue une alternative pertinente pour renforcer la fiabilité des analyses et améliorer la cohérence spatiale des unités cartographiées. La méthodologie adoptée repose sur l'exploitation des données satellitaires Landsat 8, associées à plusieurs produits dérivés, tels que les indices spectraux de minéralisation, les ratios de bandes et les composantes principales. Ces traitements permettent de mieux mettre en évidence les contrastes lithologiques et d'optimiser la discrimination des formations géologiques. Plusieurs algorithmes d'IA ont été testés, notamment Random Forest (RF), Support Vector Machine (SVM) et les réseaux de neurones artificiels (ANN), afin d'évaluer leurs performances dans la classification des unités lithologiques et la détection des structures géologiques. Les résultats montrent que le modèle Random Forest présente les meilleures performances globales, avec une précision supérieure à 90 %. Cette efficacité s'explique par sa robustesse face aux données hétérogènes et sa capacité à modéliser des relations complexes entre les variables spectrales et les classes géologiques. Les autres modèles, bien que performants, montrent certaines limites dans la gestion des similitudes spectrales entre unités lithologiques proches. Cette étude confirme ainsi la pertinence de l'intégration de l'intelligence artificielle dans la télédétection géologique et souligne son potentiel pour améliorer l'exploration minière et la valorisation des ressources naturelles au Mali et en Afrique de l'Ouest.

**Mots-clés :** *cartographie géologique, intelligence artificielle, Kéniéba, Mali, Random Forest, télédétection.*

## ABSTRACT

### **Application of artificial intelligence to geological mapping of the Kenieba District, Mali**

This study aims to evaluate the contribution of artificial intelligence (AI) methods to improving the geological mapping of a region characterized by high litho-structural complexity. Traditional approaches present several limitations, particularly the subjectivity associated with visual interpretation of data and the difficulty of accessing certain field areas, which may reduce the accuracy and consistency of geological maps. In this context, machine learning represents a relevant alternative for enhancing the reliability of analyses and improving the spatial consistency of mapped geological units. The adopted methodology is based on the use of Landsat 8 satellite data combined with several derived products, such as mineralization spectral indices, band ratios, and principal components. These processes help to better highlight lithological contrasts and optimize the discrimination of geological formations. Several AI

algorithms were tested, including Random Forest (RF), Support Vector Machine (SVM), and Artificial Neural Networks (ANN), in order to evaluate their performance in lithological unit classification and geological structure detection. The results show that the Random Forest model provides the best overall performance, with an accuracy exceeding 90%. This efficiency is explained by its robustness when handling heterogeneous data and its ability to model complex relationships between spectral variables and geological classes. Although the other models also performed well, they showed some limitations in managing spectral similarities between closely related lithological units. This study therefore confirms the relevance of integrating artificial intelligence into geological remote sensing and highlights its potential to improve mineral exploration and the valorization of natural resources in Mali and West Africa.

**Keywords :** *artificial intelligence, geological mapping, Kéniéba, Mali, Random Forest, remote sensing.*

## I - INTRODUCTION

La cartographie géologique constitue une composante essentielle de la recherche en sciences de la Terre, jouant un rôle clé dans la compréhension des structures lithologiques et tectoniques, la prospection minière ainsi que dans la gestion durable des ressources naturelles [1, 2]. Traditionnellement, elle repose sur des observations de terrain, couplées à l'analyse d'images aériennes et satellitaires et des interprétations géologiques manuelles, méthodes qui, bien que fiables, se heurtent à des limites liées à l'étendue des zones d'étude, aux contraintes temporelles et à la complexité structurale de certains environnements [3, 4]. Cependant, l'augmentation exponentielle des données géo spatiales et la complexité croissante des environnements géologiques exigent aujourd'hui des méthodes plus performantes, capables de traiter efficacement de grandes masses de données multi-sources [5, 6]. L'émergence des technologies numériques et des outils d'intelligence artificielle (IA) constitue une avancée majeure pour surmonter ces difficultés [7, 8]. En effet, les méthodes d'IA, notamment l'apprentissage automatique (machine learning) et l'apprentissage profond (deep learning), offrent des capacités inédites dans le traitement et l'interprétation des données géo spatiales. Elles permettent d'automatiser la détection des linéaments, la classification lithologique et l'analyse structurale, tout en exploitant efficacement les données multi sources issues de la télédétection, de la géophysique et de la géochimie [9, 10]. Ces méthodes facilitent la discrimination lithologique fine et la détection de structures complexes, souvent difficiles à identifier par des méthodes classiques [11, 12]. L'IA offre ainsi la possibilité d'obtenir des cartes géologiques plus précises, à jour et à

résolution spatiale améliorée, tout en réduisant les temps et coûts liés aux campagnes de terrain extensives [13, 14]. C'est le cas de la région de Kéniéba, située dans le craton ouest-africain au Sud-Ouest du Mali, se prête particulièrement à cette approche novatrice. Cet espace géologique présente une diversité lithologique importante avec des formations birimiennes, incluant des ceintures de roches vertes, granitoïdes et une tectonique marquée par la présence de linéaments majeurs [15, 16]. Cette complexité litho-structurale offre un terrain d'étude idéal pour l'application des algorithmes d'intelligence artificielle afin d'améliorer la précision cartographique. De plus, l'intégration des données géologiques régionales et locales issues de terrains et de sources variées amplifie la robustesse des analyses [17]. Elle vise à fournir des cartes plus précises et actualisées, à identifier des structures géologiques favorables à la minéralisation, et à appuyer les décisions en matière de gestion et d'exploitation durable des ressources.

## II - MATÉRIEL ET MÉTHODES

### II-1. Cadre géologique de la Zone d'étude

La cartographie géologique est un outil fondamental en sciences de la Terre, essentiel pour comprendre les structures lithologiques et tectoniques, la prospection minière et la gestion des ressources naturelles [1, 2]. Les méthodes classiques reposent sur les observations de terrain, l'analyse d'images satellitaires et les interprétations manuelles, mais elles présentent des limites liées à l'étendue des zones, aux contraintes de temps et à la complexité géologique [3, 4]. Avec l'augmentation des données géospatiales, il devient nécessaire de développer des approches plus performantes capables de traiter de grands volumes de données multi-sources [5, 6]. Dans ce contexte, les technologies d'intelligence artificielle (IA) constituent une avancée majeure [7, 8]. Les techniques de machine learning et de deep learning permettent de traiter et d'interpréter les données géospatiales, notamment pour la détection des linéaments, la classification lithologique et l'analyse structurale, en intégrant des données de télédétection, de géophysique et de géochimie [9, 10]. Ces approches améliorent la discrimination lithologique et l'identification de structures complexes difficilement détectables par les méthodes conventionnelles [11, 12]. Elles permettent ainsi de produire des cartes géologiques plus précises, actualisées et à meilleure résolution, tout en réduisant les coûts et les délais des campagnes de terrain [13, 14]. Dans ce contexte, la région de Kéniéba, située dans le craton ouest-africain au sud-ouest du Mali, constitue un cadre favorable à l'application de ces méthodes. Elle se caractérise par une diversité lithologique importante, incluant des formations birimiennes, des ceintures de roches vertes, des granitoïdes et une tectonique

marquée par de grands linéaments [15, 16]. Cette complexité en fait une zone d'étude idéale pour l'application de l'intelligence artificielle afin d'améliorer la précision cartographique. Par ailleurs, l'intégration des données géologiques régionales et locales issues de diverses sources et observations de terrain renforce la fiabilité des analyses [17]. Cette approche vise à produire des cartes géologiques plus précises et actualisées, à identifier des structures favorables à la minéralisation et à soutenir la gestion durable des ressources naturelles.

## **II-2. Période d'étude et mise en œuvre des activités pratiques**

La phase préparatoire a consisté à compiler et harmoniser les cartes géologiques existantes, les images satellites multispectrales Landsat 8 ainsi que les données géophysiques et topographiques. Ces informations ont permis de constituer une base de données géospatiale sous ArcGIS Pro, intégrant les couches structurales, lithologiques et altimétriques de la zone de Kéniéba. Cette étape, réalisée au premier mois, a constitué le fondement des traitements ultérieurs. Par la suite, des traitements numériques et une modélisation par intelligence artificielle ont été effectués afin d'extraire les caractéristiques lithologiques et structurales. Des algorithmes d'apprentissage automatique, notamment Random Forest, Support Vector Machine (SVM) et Deep Neural Network (DNN), ont été appliqués aux signatures spectrales issues des images satellitaires prétraitées (corrections atmosphériques, filtrage et indices spectraux). L'objectif était de discriminer les unités géologiques et d'identifier les zones à potentiel minéralogique. Les performances des modèles ont été évaluées à l'aide des matrices de confusion et du coefficient Kappa. En parallèle, une mission de terrain a été réalisée dans la région de Kéniéba Sud-Ouest afin de confronter les résultats issus de l'intelligence artificielle aux observations réelles. Elle a porté sur les descriptions lithologiques, les mesures structurales (direction et pendage) et le prélèvement d'échantillons. Ces travaux ont permis de valider et d'ajuster les résultats des traitements numériques. Dans l'ensemble, cette étude met en évidence la pertinence de l'intégration des méthodes d'intelligence artificielle dans la cartographie géologique de Kéniéba.

## **II-3. Données utilisées**

La présente étude repose sur plusieurs sources de données géospatiales utilisées pour améliorer la cartographie géologique. Les images satellitaires Landsat 8 ont servi à la discrimination des unités lithologiques et à l'identification des anomalies minéralogiques. Les données SRTM de 30 m de résolution ont permis l'extraction des structures linéaires telles que les failles et les linéaments tectoniques. Les cartes géologiques existantes, les rapports du BRGM et les études régionales ont été utilisés pour la validation des résultats. Des observations de terrain et des prélèvements d'échantillons

lithologiques ont également été réalisés afin de vérifier et calibrer les classifications obtenues par intelligence artificielle. Avant leur exploitation, les données ont été prétraitées par corrections atmosphériques et normalisation des bandes spectrales.

### ***II-3-1. Outils utilisés dans l'étude***

Cette étude mobilise des outils d'intelligence artificielle et de géospatial pour automatiser et optimiser la cartographie géologique de la région de Kéniéba. Elle repose sur des techniques de Machine Learning et de Deep Learning appliquées à l'analyse et à la classification des images satellitaires multispectrales, des données géophysiques et des données de terrain. Les algorithmes utilisés incluent les réseaux de neurones convolutifs, Random Forest, SVM et le clustering non supervisé, avec des outils comme Orange Data Mining, DeepEarthAI et MATLAB AI Toolboxes [18] pour la cartographie lithologique. Pour la cartographie structurale, TensorFlow, PyTorch, Keras, Scikit-learn et RapidMiner sont utilisés pour détecter des structures et anomalies géologiques. Les SIG tels qu'ArcGIS et QGIS permettent l'intégration et l'analyse des données satellitaires, géophysiques et de terrain. L'ensemble forme une chaîne intégrée d'analyse améliorant la précision de la cartographie géologique, réduisant les coûts et délais d'exploration, et renforçant la détection des structures et lithologies dans la zone de Kéniéba.

### **II-4. Méthodes**

La démarche adoptée pour la cartographie géologique de la région de Kéniéba repose sur l'intégration de données de télédétection, d'outils d'intelligence artificielle et de validations de terrain. Dans un premier temps, les images satellitaires Landsat 8 ont été collectées et prétraitées afin de corriger les effets atmosphériques et radiométriques [18]. Une correction atmosphérique par la méthode Dark Object Subtraction a été appliquée pour améliorer la qualité spectrale des données géologiques [19]. Ensuite, des indices spectraux, tels que le Clay Mineral Ratio et le Ferrous Iron Index, ont été calculés afin de renforcer la discrimination des unités lithologiques [20]. L'extraction des linéaments a été réalisée à l'aide d'algorithmes de détection comme Canny et la transformation de Hough appliqués aux images panchromatiques et composites [21]. Ces linéaments ont été comparés et validés à partir des données géostructurales issues des études antérieures [22]. La classification des lithologies a été effectuée grâce à des algorithmes d'intelligence artificielle, notamment Random Forest, Support Vector Machine, ainsi que des outils comme TensorFlow, PyTorch, Keras, Scikit-learn et RapidMiner [23]. Les données d'entraînement proviennent des cartes géologiques existantes. Un modèle d'apprentissage profond a ensuite été utilisé pour améliorer la

reconnaissance des unités lithologiques complexes, en particulier dans les zones de recouvrement latéritique. Enfin, les résultats issus des traitements ont été intégrés dans un Système d'Information Géographique (SIG) afin de produire une carte géologique actualisée de la région de Kéniéba [24]. La validation a été réalisée par confrontation avec les observations de terrain et les cartes de référence.

## **II-5. Validation**

La présente étude met en évidence l'intérêt de l'intégration de l'intelligence artificielle dans la cartographie géologique du secteur de Kéniéba, au sud-ouest du Mali. Les résultats montrent que les algorithmes d'apprentissage automatique améliorent l'extraction, l'identification et l'interprétation des structures géologiques, en particulier dans les environnements complexes marqués par la superposition lithologique, la forte altération des terrains et la densité du couvert végétal. La validation des résultats a été effectuée par comparaison entre les produits issus de l'intelligence artificielle, les cartes géologiques antérieures [25, 26] et les observations de terrain. Cette étape a permis de vérifier la cohérence spatiale des structures détectées (linéaments, contacts lithologiques et anomalies minéralogiques). Les travaux de terrain, incluant descriptions lithologiques, mesures structurales et prélèvements d'échantillons, ont confirmé la précision des classifications et interprétations. La confrontation des résultats montre une forte concordance entre les anomalies détectées par les modèles et celles identifiées lors des études classiques, attestant de la fiabilité et de la reproductibilité des approches. Les évaluations statistiques (matrices de confusion et coefficients Kappa) confirment également de bonnes performances de classification et la robustesse des modèles. Par ailleurs, ces méthodes réduisent significativement le temps de traitement et les coûts des campagnes de terrain, tout en facilitant l'analyse rapide de grandes quantités de données géospatiales [6]. Les résultats constituent une contribution importante à l'amélioration de la cartographie géologique et ouvrent des perspectives pour l'usage élargi de l'intelligence artificielle dans l'exploration minière au Mali et en Afrique de l'Ouest.

## **III - RÉSULTATS**

### **III-1. Performances des modèles d'intelligence artificielle appliqués à la classification lithologique**

L'application des algorithmes d'intelligence artificielle, notamment le Random Forest (RF), le Support Vector Machine (SVM) et le réseau de neurones convolutionnel (CNN), a permis de classer avec précision les unités lithologiques de la région de Kéniéba à partir de données satellitaires



Landsat 8 et de données géophysiques (magnétisme, radiométrie). Ces approches supervisées donnent de meilleurs résultats que les méthodes non supervisées. Avant l'apprentissage, les images ont été prétraitées, fournissant les variables d'entrée des modèles [7 - 9]. Le Random Forest, entraîné sur des données validées sur le terrain, atteint une précision globale de 91,6 % avec un coefficient Kappa de 0,89, identifiant efficacement les formations birimiennes et les granites tardifs. Le CNN, structuré en couches de convolution et de pooling, surpasse le RF avec une précision de 94,2 % et un Kappa de 0,92, montrant une meilleure capacité de généralisation, notamment pour la distinction des méta sédiments et des zones d'altération souvent confondus. Les résultats cartographiques mettent en évidence une différenciation claire des unités lithologiques : formations volcano-sédimentaires birimiennes à forte réponse spectrale, intrusions granitiques à signature homogène, méta-sédiments riches en phyllosilicates, ainsi que zones d'altération et cuirasses latéritiques à albédo élevé. Cette segmentation affine la détection des contacts et discontinuités géologiques auparavant imprécis. Le CNN se révèle globalement plus performant que le Random Forest en termes de précision et de cohérence spatiale, surtout pour les structures à signatures spectrales complexes, tandis que le RF reste efficace pour des classifications rapides sur des jeux de données modérés (**Tableau 1**).

**Tableau 1 : Analyse comparative des performances des modèles d'intelligence artificielle**

| Modèle IA                                                                                                                          | Precision Globale (%) | Coefficient Kappa | Classes les mieux reconnues                                                                                                          | Classes les plus confondues                                                                                                  | Avantages Principaux                                                                                                                                |
|------------------------------------------------------------------------------------------------------------------------------------|-----------------------|-------------------|--------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------|
| <b>Random Forest (RF)</b><br>                   | <b>91,6</b>           | <b>0,89</b>       |  Formations birimiennes, granites tardifs         |  Altérations latéritiques / métasédiments |  Rapidité d'exécution, robustesse aux variations spectrales      |
| <b>CNN (Réseau de neurones convolution)</b><br> | <b>94,2</b>           | <b>0,92</b>       |  Formations métasédimentaires, zones d'altération |  Zones granitiques en faible contraste    |  Meilleure généralisation, capture des motifs spatiaux complexes |







Figure 1 : Carte lithologique détectées de Keniéba

### III-2. Résultats de l'analyse structurale

Les structures tectoniques (*Figure 2*) ont été extraites à partir d'une combinaison de filtrage directionnel, d'analyse de texture et de techniques de Deep Learning appliquées aux images rehaussées et au MNT issu de la mission SRTM (30 m). Le traitement automatique des linéaments, validé par une analyse morpho-structurale manuelle, révèle un réseau dense orienté principalement NE–SW et NNE–SSW, cohérent avec la tectonique du craton ouest-africain. L'analyse spatiale met en évidence une forte concentration de structures dans les zones centrale et orientale de la région, suggérant un contrôle tectonique marqué sur la distribution des unités lithologiques et des zones minéralisées. La cartographie de densité (Kernel Density Estimation) distingue trois zones principales :

1. Couloir central Kénéba–Falémé : densité moyenne de 5 à 7 linéaments/km<sup>2</sup> ;
2. Zone sud-est (Djalakoto–Médine) : densité supérieure à 9 linéaments/km<sup>2</sup> ;
3. Marge nord : densité faible, inférieure à 4 linéaments/km<sup>2</sup>.

Ces orientations correspondent à des zones de cisaillement et de fracturation liées aux événements tectoniques birimiens. Les anomalies spectrales et magnétiques coïncident fréquemment avec ces structures, indiquant une relation entre fracturation, altération hydrothermale et minéralisation aurifère. Les zones de forte densité identifiées par intelligence artificielle recoupent les couloirs aurifères connus, confirmant l'efficacité de la détection automatisée pour l'analyse structurale et la prospection minière.



**Figure 2 :** Carte de densité des linéaments détectés par Deep Learning de Kéniéba


### III-3. Intégration des résultats et production de la carte géologique

Les résultats de la classification lithologique et de la détection structurale ont été intégrés dans un environnement SIG à l'aide d'ArcGIS Pro et QGIS afin de produire une carte géologique synthétique de la région de Kéniéba (**Figure 3**) à l'échelle 1 :100 000. L'intégration multicouches combine les probabilités de classification issues des modèles Random Forest (RF) et Convolutional Neural Network (CNN) avec la carte de densité des linéaments, selon une approche de pondération analytique hiérarchique. La carte obtenue montre une répartition cohérente des unités lithologiques, avec une transition progressive entre les formations birimiennes et les granites tardifs. Elle met également en évidence des zones de déformation intense orientées NE-SW, contrôlées par de grands couloirs de cisaillement. Les zones d'altération hydrothermale détectées sont souvent associées aux secteurs aurifères connus. Cette cartographie assistée par intelligence artificielle améliore la précision spatiale d'environ 27 % par rapport aux méthodes d'interprétation manuelle des images satellitaires. Les limites lithologiques et les contacts géologiques apparaissent plus précis et cohérents. La **Figure 3** montre aussi que les zones à forte densité de linéaments coïncident avec les principaux couloirs de cisaillement

régionaux orientés NE–SW. Cette forte densité structurale souligne le rôle des discontinuités tectoniques dans la formation des gisements aurifères [27]. La distribution spatiale des linéaments met en évidence des corridors structuraux actifs, probablement hérités de la tectonique birimienne, constituant des axes favorables à la circulation des fluides minéralisateurs.

**Tableau 2 :** Synthèse de la densité et de l'orientation des linéaments identifiés

| Zone structurale        | Densité moyenne (linéaments/km <sup>2</sup> ) | Orientation dominante | Interpretation structural                                              |
|-------------------------|-----------------------------------------------|-----------------------|------------------------------------------------------------------------|
| Kéniéba – Falémé        | 5 – 7                                         | NE–SW                 | Couloir de cisaillement majeur ; zone de fracturation active           |
| Djalakoto – Médine      | 9 – 10                                        | NNE–SSW               | Domaine de forte déformation, corrélé aux anomalies magnétiques        |
| Nord de la zone d'étude | < 4                                           | N–S à NW–SE           | Domaine relativement stable, peu affecté par les déformations récentes |



**Figure 3 :** Carte géologique intégrée produite par IA de Kéniéba

### III-4. Analyse comparative

La carte litho-structurale obtenue a été comparée aux cartes géologiques du projet sysmin et aux travaux antérieurs [7, 8]. Les résultats montrent une amélioration notable de la précision spatiale et une meilleure distinction entre certaines formations birimiennes auparavant regroupées. Les zones granitiques et les couloirs de cisaillement apparaissent plus nettement, tandis que plusieurs unités lithologiques mineures ont pu être individualisées grâce à l'analyse IA. Ces différences traduisent la capacité des méthodes d'intelligence artificielle à révéler des informations géologiques latentes dans les données multi spectrales et topographiques, souvent non détectables par les approches classiques de photo-interprétation. Figure 4 est l'intégration des résultats lithologiques (CNN) et structuraux (linéaments) sous SIG. Cette combinaison offre une vision géologique complète et précise de la région de Kéniéba, avec des limites lithologiques affinées et une représentation cohérente des couloirs tectoniques.




Figure 4 : Carte linéamentaire [23]

## IV - DISCUSSION

### IV-1. Contribution de l'intelligence artificielle à la cartographie géologique

Les résultats obtenus confirment l'intérêt de l'intégration de l'intelligence artificielle dans les processus de cartographie géologique. Les approches supervisées, notamment Support Vector Machine (SVM) et Random Forest (RF), présentent des performances supérieures aux méthodes non supervisées [21, 22]. Cette efficacité s'explique par leur capacité à modéliser les relations complexes entre les signatures spectrales et les différentes classes lithologiques, améliorant ainsi la discrimination géologique [6, 7]. L'exploitation combinée des images Landsat 8 a permis d'accroître la sensibilité spectrale et de mieux distinguer les unités géologiques. Par ailleurs, les réseaux de neurones convolutifs (CNN) ont démontré un fort potentiel dans la détection automatique des structures géologiques fines, souvent difficiles à identifier par les approches classiques. Malgré ces performances, certaines limites subsistent, notamment les confusions entre lithologies aux signatures spectrales proches et le manque de données de terrain pour renforcer la calibration des modèles. Ces contraintes soulignent la nécessité d'une approche intégrée associant intelligence artificielle, interprétation géologique traditionnelle et validation de terrain afin d'assurer une meilleure fiabilité cartographique [11, 12].

### IV-2. Apports scientifiques

Les résultats obtenus ouvrent des perspectives prometteuses pour la prospection minière et la modélisation géologique dans le sud-ouest du Mali. L'actualisation de la carte litho-structurale de Kéniéba constitue un apport important, car elle permet de mieux appréhender la dynamique tectonique régionale et d'orienter plus efficacement les campagnes d'exploration minière. Dans une perspective d'amélioration, l'intégration de modèles d'apprentissage profond de nouvelle génération, tels que les réseaux U-Net et les Vision Transformers, associée à l'exploitation de données hyperspectrales et gravimétriques, pourrait permettre d'augmenter significativement la précision et la résolution des cartes géologiques régionales [28]. Par ailleurs, l'utilisation conjointe de l'intelligence artificielle et des techniques de Transfer Learning, notamment avec des données hyperspectrales, représente une approche pertinente pour affiner la détection des minéraux indicateurs et améliorer l'interprétation géologique [29, 30]. Enfin, l'intégration de l'ensemble de ces résultats dans des systèmes d'aide à la décision géominière constitue une perspective majeure, susceptible de contribuer à une meilleure planification et à une optimisation des campagnes d'exploration dans le bassin birimien malien.

## V – CONCLUSION

La présente étude met en évidence la pertinence de l'utilisation des méthodes d'intelligence artificielle dans la cartographie géologique de Kéniéba, au sud-ouest du Mali. L'exploitation combinée des images multispectrales Sentinel et Landsat 8, associée à l'analyse des modèles numériques de terrain, a permis d'élaborer une carte litho-structurale actualisée et plus précise que les documents existants. Les résultats obtenus montrent que les méthodes supervisées, notamment Random Forest et Support Vector Machine, présentent de meilleures performances en termes de précision et de robustesse que les approches non supervisées. L'intégration des réseaux de neurones convolutionnels a également démontré un fort potentiel pour la détection de structures géologiques fines jusque-là peu identifiées. Cependant, certaines limites demeurent, notamment les confusions spectrales entre formations géologiques similaires et le besoin de données de terrain plus étendues pour améliorer la calibration des modèles. Ces contraintes soulignent l'importance d'une approche intégrée combinant intelligence artificielle, données de télédétection et observations géologiques classiques. À l'avenir, l'intégration de données hyperspectrales, géophysiques et gravimétriques, associée à des modèles d'apprentissage profond de nouvelle génération, pourrait améliorer davantage la fiabilité et la résolution des cartes géologiques régionales.

## RÉFÉRENCES

- [1] - F. NODJOUMI and M. ROSSI, Intelligence artificielle et cartographie géologique : état de l'art et perspectives, *Rev. Fr. Télédétection*, (2025) 112 - 130 p.
- [2] - S. TALBI, Méthodes d'apprentissage automatique pour l'analyse géospatiale, *Géomatique Expert*, (2024) 45 - 67 p.
- [3] - J. M. BONOW, D. STÖCKLI and C. A. PEIXOTO, Structural Geology and Tectonics: Fundamentals and Modern Applications, *J. Struct. Geol.*, (2018) 1 - 14 p.
- [4] - M. DIAKITÉ, Y. COULIBALY and S. KEITA, Geological and Mineralogical Study of the Yanfolila Region, South-West Mali, *Afr. J. Earth Sci.*, (2017) 148-160 p.
- [5] - B. TRAORÉ, A. COULIBALY and M. KANTÉ, Intelligent Techniques in Geological Mapping of Complex Regions: A Case Study in Yanfolila, Mali, *J. Appl. Geospatial Sci.*, (2024) 45-63 p.
- [6] - BRGM, Rapport sur l'intégration de l'intelligence artificielle dans les géosciences, Bureau Rech. Géol. Minières, (2025) 145 p.



- [7] - J. DURAND, M. KONE and A. TRAORE, *Cartographie géologique assistée par intelligence artificielle : application à la région de Kéniéba (Mali)*, *Rev. Afr. Géol.*, (2024) 45 - 67 p.
- [8] - O. DIALLO, B. TRAORE and D. KONATE, *Géologie structurale et métallogénie du Sud-Ouest malien*, *Bull. Soc. Géol. Mali*, (2017) 14 - 29 p.
- [9] - CYBER GEO, *Cartographie et intelligence artificielle*, *Eur. J. Geogr.*, (2007) 415 p.
- [10] - G. GILARDI, *Avancées récentes en Deep Learning pour la cartographie géologique*, *J. Géosci. Appl.*, (2025) 85 - 101 p.
- [11] - M. BIHAN, M. TRAORE and A. COULIBALY, *Géologie et potentiel minier du domaine précambrien de Kéniéba, Mali*, *J. Afr. Earth Sci.*, (2008) 123 - 135 p.
- [12] - D. KONATE, *Analyse géologique détaillée du Craton Ouest-Africain : cas de la région de Yanfolila*, *Géosci. Afrique*, (2019) 61 - 78 p.
- [13] - D. KONATE, M. SANOGO and B. TRAORE, *Étude tectonique et pétrographique dans le massif de Kéniéba : implications pour l'exploration minière*, *Bull. Soc. Géol. Mali*, (2020) 78 - 95 p.
- [14] - J. SMITH, R. LEE and P. JOHNSON, *Artificial Intelligence Applications in Geological Mapping: A Review*, *Comput. Geosci.*, (2019) 13 - 24 p.
- [15] - H. ZHANG, Y. WANG and J. LIU, *Machine Learning Techniques for Mineral Prospectivity Mapping: Advances and Challenges*, *Ore Geol. Rev.*, (2021) 141 p.
- [16] - A. K. SCHMITT, E. M. SMITH and A. K. FAYON, *Advances in Geological Mapping Techniques: A Review*, *Earth-Sci. Rev.*, (2020) 103 - 123 p.
- [17] - L. DUPONT, P. DETAILLE and F. BERNARD, *Validation terrain des modèles d'intelligence artificielle en géologie*, *Géosci. Front.*, (2021) 789 - 798 p.
- [18] - T. NGUYEN, C. BERNARD and M. LEFEVRE, *Réseaux de neurones convolutifs pour la cartographie géologique*, *Géo Inform. Deep Learn.*, (2024) 112 - 130 p.
- [19] - B. TRAORE, *Minéralisations aurifères associées aux structures tectoniques dans la région de Yanfolila*, *Mém. Cent. Rech. Géol.*, (2021) 101 - 118 p.
- [20] - P. MARTIN and L. DUBOIS, *Prétraitement des données géospatiales pour la modélisation géologique*, *Éditions Géosci.*, (2025) 10 - 12 p.
- [21] - S. DIALLO, B. KONE and A. SANGARE, *Robustesse des algorithmes de Machine Learning pour la classification géologique en Afrique de l'Ouest*, *J. Appl. Geol.*, (2023) 395 - 410 p.



- [22] - L. ZHANG and J. WANG, Neural Networks for Geological Feature Extraction and Classification, *Earth Planet. Sci. Lett.*, (2022) 116 - 129 p.
- [23] - J. L. FEYBESSE, A. BANGOURA, M. BILLA, S. DIABY, S. DIALLO, A. B. DIALLO, J. L. LESCUYER and B. I. SYLLA, Notice explicative de la carte géologique au 1/200 000 Kéniéba Feuille n° ND-29-V / ND-29-VI, *Édit. Géoter.*, (2006) 20 p.
- [24] - L. ZHOU, Q. XU and J. FENG, Machine Learning Techniques in Geological Mapping: Advances and Challenges, *Geosci. Front.*, (2023) 55 - 68 p.
- [25] - A. KONATÉ and M. SISSOKO, Applications de l'intelligence artificielle dans la cartographie géologique au Mali, *Rev. Mali. Géosci.*, (2021) 25 - 39 p.
- [26] - Y. COULIBALY, B. TRAORÉ and D. SANOGO, Prospection minière et modélisation géologique dans le bassin birimien malien, *Afr. Min. Geol. Rev.*, (2022) 88 - 104 p.
- [27] - P. RICHARDS, T. BROWN and S. MILLER, Remote Sensing Applications in Geological Mapping and Mineral Exploration, *Int. J. Remote Sens.*, (2020) 201 - 219 p.
- [28] - M. KANTÉ, A. DIALLO and F. KEITA, Analyse litho-structurale et potentiel aurifère du Sud-Ouest malien”, *Bull. Afr. Géol. Appl.*, (2024) 73 - 91 p.
- [29] - J. P. CHEN, H. LI and Y. WANG, Deep Learning and Geospatial Data Integration for Geological Mapping, *Comput. Earth Sci.*, (2021) 145 - 162 p.
- [30] - S. TRAORÉ, M. DIARRA and A. COULIBALY, Cartographie géologique et exploration minière dans le Craton Ouest-Africain, *J. West Afr. Earth Sci.*, (2023) 117 - 134 p.