

Utilisation de l'apprentissage profond et de la combinaison des images multi capteurs pour la cartographie de l'utilisation et de la couverture des sols dans le bassin versant de la Marahoué

[Using Deep Learning and the combination of multi-sensor images to map land use and land cover in the Marahoué watershed]

Kamenan Satti Jean Robert¹, Youan Ta Marc^{2,3}, Adja Miessan Germain⁴, and Kouassi Amani Michel⁵

¹Institut National Polytechnique Félix HOUPOUET-BOIGBY, Ecole doctorale polytechnique STI, UMRI Sciences et Techniques de l'ingénieur, Laboratoire des Sciences Géographiques, du Génie Civil et des Géosciences, Côte d'Ivoire

²Centre Universitaire de Recherche Appliquée en Télédétection (CURAT), Université Félix Houphouët-Boigny, Abidjan, Côte d'Ivoire

³Unité de Formation et de Recherche des Sciences de la Terre et des Ressources Minières (UFR-STRM), Université Félix Houphouët-Boigny d'Abidjan-Cocody, Abidjan, Côte d'Ivoire

⁴Sciences de la Vie et de la Terre (SVT), École Normale Supérieure (ENS), Abidjan, Côte d'Ivoire

⁵Institut National Polytechnique Félix HOUPOUET-BOIGBY, Ecole Supérieure des Mines et Géologie, UMRI Sciences et Techniques de l'ingénieur, Laboratoire des Sciences Géographiques, du Génie Civil et des Géosciences, Côte d'Ivoire

Copyright © 2025 ISSR Journals. This is an open access article distributed under the ***Creative Commons Attribution License***, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

ABSTRACT: Knowledge of information related to land use and land cover in a region is necessary for urbanization projects, sustainable development and natural risk management, particularly floods. The aim of this article is to explore the use of Artificial Intelligence techniques and the combination of multi-sensor images to map land use and land cover in the Marahoué region. To this end, the Deep Forest algorithm is used as the main classifier. Its construction required the use of three common classifiers Extreme Gradient Boosting (XGB), Random Forest (RF) and Extra Tree (ET). Three Deep Forest models (DF-XGB; DF-RF; DF-ET) were developed and optimized to guarantee optimum accuracy. These DF models were then compared with four (04) classifiers commonly used in land use studies (RF, XGB, CNN, CART). The results indicate that the DF-XGB model outperformed all conventional classifiers by over 96%, confirming the relevance of integrated approaches mobilizing multi-sensor data, spectral indices and advanced classifiers. The predominance of cultivated land, the regression of forest formations and the localized presence of wetlands identified by the DF-XGB model, reflect the ongoing dynamics of anthropization. This approach thus offers a powerful tool for environmental monitoring, sustainable community management and flood risk prevention in the Marahoué watershed.

KEYWORDS: Deep Learning, Land cover, Google earth engine, Remote sensing, Marahoué, Ivory Coast.

RESUME: La connaissance des informations liées à l'utilisation et de la couverture des sols dans une région est nécessaire pour les projets d'urbanisation, de développement durable et de gestion des risques naturels notamment celles des inondations. Ainsi cet article se propose d'explorer les techniques de l'Intelligence Artificielle et de la combinaison des images multi capteurs pour cartographier l'utilisation et la couverture du sol dans la région de la Marahoué. À cet effet, l'algorithme Deep Forest est utilisé comme principal classificateur. Sa construction a nécessité l'utilisation de trois classificateurs usuels Extreme Gradient Boosting (XGB), Random Forest (RF) et Extra Tree (ET). Ainsi trois modèles du Deep Forest (DF-XGB; DF-RF; DF-ET) ont été développés puis optimisés afin de garantir une précision optimale. Ensuite ces modèles DF ont été comparés à quatre (04) classificateurs couramment utilisés dans les études d'occupation du sol (RF, XGB, CNN, CART). Les résultats obtenus indiquent que le modèle DF-XGB a surclassé tous les classificateurs

conventionnels avec un taux de plus 96 %, confirment la pertinence des approches intégrées mobilisant des données multi capteurs, des indices spectraux et des classificateurs avancés. La prédominance des terres cultivées, la régression des formations forestières et la présence localisée des zones humides identifiées par le modèle DF-XGB, traduisent les dynamiques d'anthropisation en cours. Cette approche offre ainsi un outil puissant pour le suivi environnemental, la gestion durable de la localité et la prévention des risques d'inondations dans le bassin versant de la Marahoué.

MOTS-CLEFS: Deep Learning, Occupation du sol, Google earth engine, Télédétection, Marahoué, Côte d'Ivoire.

1 INTRODUCTION

L'observation de la surface terrestre par télédétection s'impose aujourd'hui comme un outil fondamental pour l'analyse spatio-temporelle de l'environnement. L'intégration de données issues de capteurs multiples constitue une approche stratégique, largement adoptée pour améliorer la précision des analyses, en particulier dans les domaines de la cartographie de l'utilisation et de la couverture des sols. En effet, la combinaison d'images issues de capteurs optiques et radar permet de tirer parti des complémentarités spectrales, spatiales et temporelles des différentes sources d'observation. Cette fusion multi-capteurs contribue à pallier les limites individuelles des capteurs, notamment les effets de la couverture nuageuse dans les images optiques, ou la difficulté d'interprétation des signaux radar en milieu hétérogène. Plusieurs études ont ainsi démontré l'efficacité de cette approche dans l'amélioration des classifications d'occupation du sol ([1], [2], [3]). Parallèlement, les avancées récentes en intelligence artificielle, et en particulier dans le domaine de l'apprentissage automatique (Machine Learning) et de l'apprentissage profond (Deep Learning), ont profondément transformé les méthodes d'analyse des données de télédétection. La disponibilité croissante d'images satellitaires à haute résolution, tant spatiale que temporelle et spectrale, combinée à la puissance des algorithmes d'intelligence artificielle, offre aujourd'hui un contexte favorable pour un suivi plus précis, plus rapide et plus automatisé des dynamiques d'occupation des sols. En Côte d'Ivoire, et plus spécifiquement dans la région de la Marahoué, les enjeux liés à l'occupation du sol prennent une dimension critique. Cette zone, soumise à une forte pression anthropique et à des transformations rapides des écosystèmes, a connu en juin 2018 de graves inondations ayant provoqué d'importants dégâts matériels et humains. Cet événement extrême a mis en lumière la vulnérabilité croissante de cette localité face aux aléas climatiques, aggravée par une urbanisation non planifiée, la déforestation et l'altération des zones humides. Dans cette perspective, l'identification fine des unités d'occupation du sol apparaît comme un préalable indispensable pour comprendre et anticiper les risques d'inondations, adapter les politiques d'aménagement et renforcer la résilience des populations locales. Parmi les techniques récentes d'apprentissage profond, l'algorithme Deep Forest s'impose comme une méthode innovante, basée sur une architecture en cascade de forêts aléatoires et totalement indépendante des réseaux de neurones profonds. Cette approche a démontré une grande efficacité dans la classification supervisée d'images de télédétection, avec des résultats probants enregistrés dans plusieurs régions du monde, notamment en Europe, en Amérique et en Asie [4]. Toutefois, en Afrique, et plus particulièrement en Côte d'Ivoire, son potentiel reste encore largement inexploré, aucune étude scientifique ne l'ayant mobilisé à ce jour pour la cartographie de l'utilisation du sol. La présente étude vise ainsi à combler cette lacune en explorant le potentiel de l'algorithme Deep Forest combiné à l'utilisation d'images satellitaires multi-capteurs pour la cartographie de l'utilisation et de la couverture des sols dans le bassin versant de la Marahoué en Côte d'Ivoire. Ce travail s'inscrit dans la continuité des recherches antérieures menées dans le bassin de la Marahoué et ambitionne de proposer une approche méthodologique innovante et reproductible, adaptée aux conditions environnementales. Il s'agira d'évaluer, à travers une approche par pixel, la performance de l'algorithme Deep Forest dans la classification des unités d'occupation du sol, tout en identifiant les avantages et les limites de cette méthode dans un contexte africain.

2 PRÉSENTATION DE LA ZONE D'ÉTUDE

La zone d'étude est comprise entre les longitudes 5°5' et 7°1' Ouest et les latitudes 6°7' et 9°5' Nord (figure 1) et est dénommée bassin versant de la Marahoué. Sur le plan administratif (Figure 1), elle est à cheval sur les régions de la Bagoé, du Béré, du Haut-Sassandra, du Kabadougou, du Worodougou et de la Marahoué. L'environnement physique de l'espace d'étude présente un relief très contrasté marqué de plaines et des plateaux d'altitudes variant entre 400 m et 500 m [5] avec un climat soudanais dans la partie nord et un climat baouléen dans la partie sud. À ceux-ci, s'ajoutent des formations granitoïdes et des séries birimiennes qui constituent les principaux traits géologiques de la région ([6], [7]). Son réseau hydrographique est dense et caractérisé par son principal fleuve qui est la Marahoué (un affluent du fleuve Bandama), long de 550 km et ses principaux affluents le Béré à l'Est et le Yani ou Bahoroni à l'Ouest [8]. Quant à la vie socio-économique, elle est dominée par les activités agricoles, pastorales et minières [9]. Les activités agricoles sont généralement développées autour des vivriers et des produits d'exportation qui sont sous la menace permanente des inondations et de la sécheresse. La production vivrière se compose de céréales, de légumes, de fruits, de bananes plantains, des ignames, du riz et du manioc. Les cultures de rentes destinées à l'exportation sont essentiellement le coton et l'arachide auxquelles s'ajoutent l'anacarde et la mangue pour la partie septentrionale du Bassin et principalement du café et du cacao pour la région de la Marahoué et du Worodougou ([10], [11]). Concernant les activités pastorales développées à l'échelle du bassin, elles sont majoritairement tenues par les peuls transhumants venus du Mali et du Burkina-Faso. À ceux-ci, s'ajoute une classe émergente de paysans éleveurs autochtones. Ces activités

pastorales s'attellent principalement à l'élevage de bovins, soutenue elle-même par la volaille, les cheptels ovins et caprins. Concernant les activités minières, le secteur d'étude est réputé pour son exploitation aurifère dans le département de Séguéla et de Bouaflé ([12], [13]).

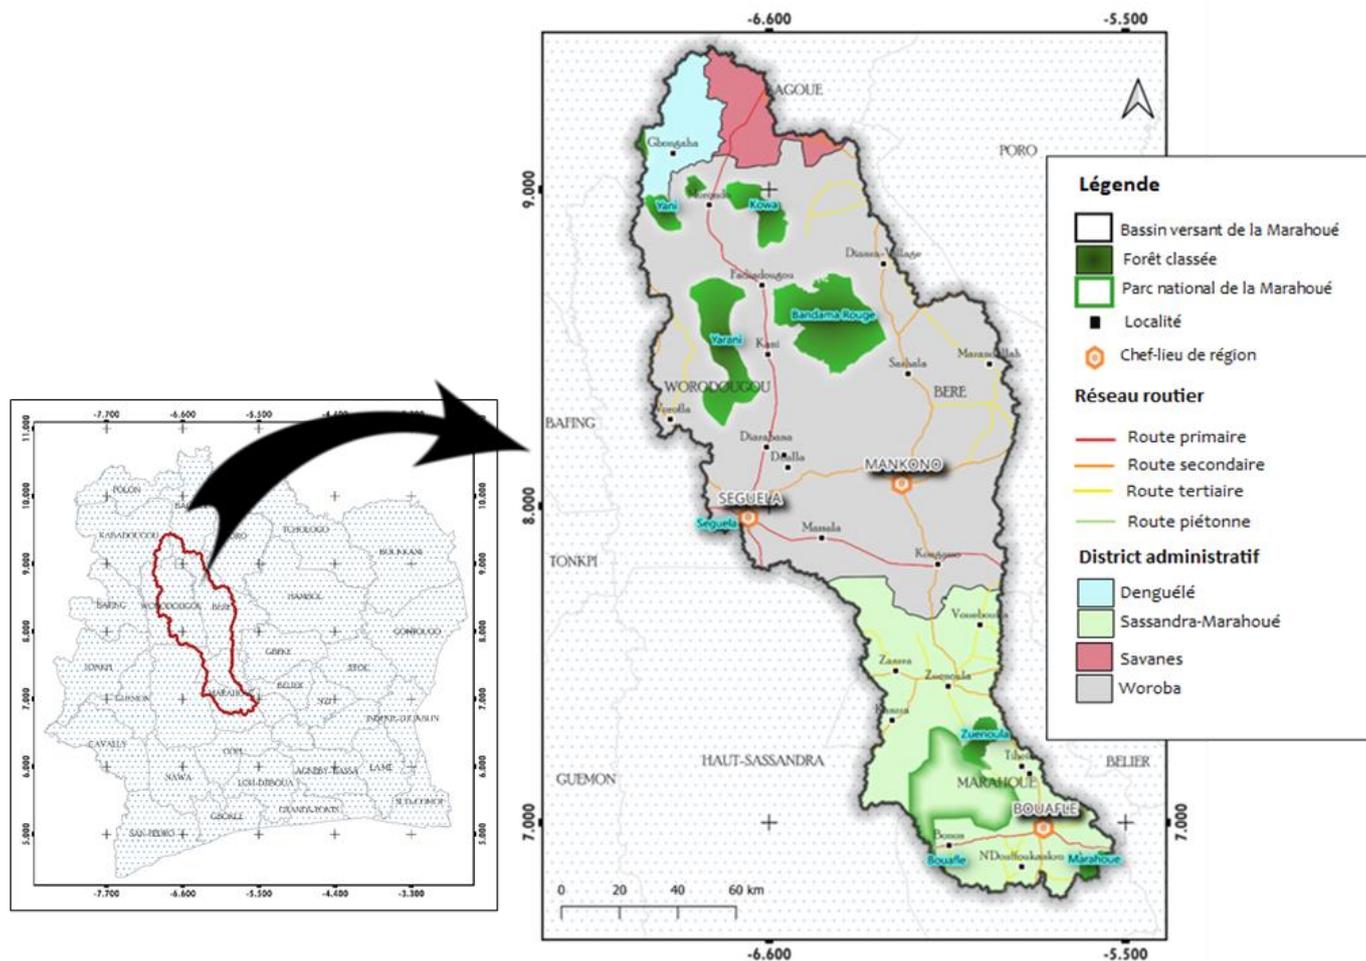


Fig. 1. Localisation de la zone d'étude

3 DONNÉES ET MATÉRIEL

Les données utilisées dans le cadre de cette étude sont essentiellement composées des observations satellitaires Sentinel-1, Sentinel-2 et Planet Scope. Concernant les images Sentinel-1, les produits de type GRDH avec deux modes de polarisation différents (VV; VH) ont été acquises via la plateforme Web Sentinel-1 Data Hub (<https://scihub.copernicus.eu>) couvrant la période 1er janvier 2018 au 31 décembre 2018 et la zone d'étude. Cette période est choisie pour mettre en évidence les inondations dévastatrices de Juin 2018 qui ont eu lieu sur cet espace. Quant aux images Sentinel-2, elles ont été acquises via la plateforme USGS Earth Explorer (<https://earthexplorer.usgs.gov/>) à la même date et à la même zone d'étude d'acquisition que celles des images SAR Sentinel-1 correspondantes. Concernant les images Planet Scope, elles sont issues d'une constellation de plus de 120 satellites CubeSat 3 U [14], nommés Doves qui sont lancées en 2016 et en 2017 [15]. Une image mosaïquée Planet Scope a été collectée à la même période et la même région que celles des images SAR Sentinel-1 correspondantes. Toutes ces images ont été collectées via la plateforme Google Earth Engine puis ont subi une série de prétraitement sur des ordinateurs équipés de plusieurs logiciels. Ces derniers sont composés de logiciels de télédétection et SIG (QGIS 3.10) pour le rendu des cartes, de logiciels de traitements (Excel) pour les statistiques.

4 METHODES

L'approche méthodologique déployée dans cette étude comprend cinq principales étapes. D'abord la discrimination des différentes unités d'occupation du sol à partir d'une classification non supervisée, de l'analyse des bandes des images issues de la phase de prétraitement et du calcul d'indices spectraux identifiés suivant un examen rigoureux de la littérature. Ensuite, des missions de terrain

de collecte d'échantillons effectuées afin de créer un jeu de données assez représentatif pour la classification. Et enfin, la classification à l'aide des algorithmes issus de l'apprentissage profond (Deep Learning), suivie de la validation de la carte d'occupation du sol et de l'évaluation de la précision des modèles

4.1 PRÉTRAITEMENT DES IMAGES SATELLITAIRES

Le prétraitement des images satellitaires est effectué en environnement Google Earth Engine et Google Colab. Il a concerné que les images Sentinel-1 (S1) et Sentinel-2 (S2). En effet, les images S1 collectées ont présenté des bruits répétitifs très aberrants bien qu'elles aient subies auparavant des traitements élémentaires (mise à jour des métadonnées de l'orbite, suppression des bruits de faible intensité, suppression du bruit additif dans les sous-bandes, calibrage radiométrique, correction du terrain Range-Doppler et la conversion du coefficient de rétrodiffusion (σ^0) en décibels (dB)) [16]. Il s'avère alors opportun de supprimer ces artefacts afin d'améliorer la qualité de des images SAR collectées. Ainsi, l'approche méthodologique adoptée, est inspirée des travaux antérieurs de [17], de [16] et de [18]. Elle se décline en trois phases agencées entre elles, lesquelles sont illustrées par la figure 2. Toutes ces phases de traitement ont été exécutées à l'aide de deux scripts, l'un en python et l'autre en javascript développés à cet effet, et ce afin d'automatiser le processus et aussi d'éviter le maximum d'erreur possible vu le nombre important d'images collectées. À la fin de ce processus toutes les scènes ont été juxtaposées pour obtenir une seule image.

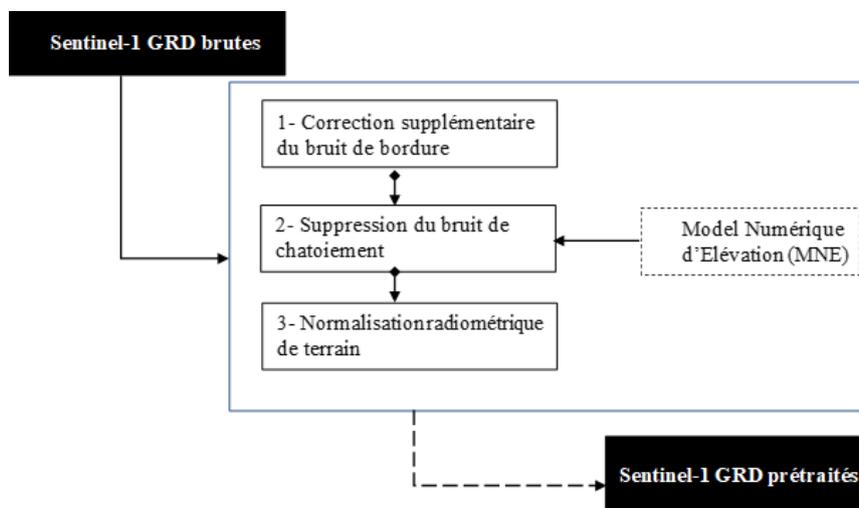


Fig. 2. Cadre méthodologie du prétraitement complémentaire des images Sentinel-1

Quant aux images Sentinel 2, elles ont été uniquement corrigées des bruits atmosphériques. En effet, les images Sentinel-2 téléchargées sur les plateformes de niveau 1C, ont déjà été corrigées des distorsions géométriques et radiométriques exceptée la correction atmosphérique ([19], [20], [21]). Cette dernière correction, effectuée sur toutes les bandes, a permis de convertir les données de réflectance de la haute atmosphère de niveau 1C en un produit de réflectance de basse atmosphère de niveau 2A [21]. Après cette étape, les bandes ayant une résolution spatiale de 20 m, ont été rééchantillonnées en 10 m en utilisant l'interpolation bilinéaire afin de faciliter l'intégration et la cohérence. Enfin, toutes les bandes initialement projetées en UTM WGS 84 ont été reprojétées dans le système UTM WGS84 zone 30N. A la fin de ce processus, toutes les scènes S2 ont été juxtaposées pour obtenir une seule image

4.2 DISCRIMINATION DES DIFFÉRENTES UNITÉS D'OCCUPATION DU SOL

Elle s'est appuyée sur l'analyse visuelle des différentes classes obtenues à l'issue d'une classification non supervisée effectuée via Google earth engine (GEE) à l'aide des bandes spectrales de Sentinel-2 prétraitées et du calcul d'un certain nombre d'indices spectraux à partir des bandes de Sentinels-2 et de Planet Scope (Tableau 1). Concernant la classification non supervisée, elle est nécessaire pour faire une cartographie exploratoire en découvrant des classes inconnues ou inattendues. Elle a consisté à regrouper automatiquement les pixels similaires sans les étiquettes et s'est effectuée à l'aide de l'algorithme k-Means disponibles dans GEE et les bandes spectrales sentinel-2. Le nombre de classes souhaité a été choisi entre l'intervalle 10 à 20 en s'appuyant sur des classes existantes dans la zone d'étude. Quant aux indices de télédétection, ils ont été identifiés et sélectionnés fort de leur contribution dans la discrimination des classes d'occupation de sol ([22], [23], [24]). À la suite de cela, il a été jugé pertinent de la création d'une bande supplémentaire VH/VV des images Sentinel-1. Cette dernière se définissant comme le ratio des bandes VH et VV a déjà fait ses preuves dans la classification des unités d'occupation du sol dans diverses régions du monde [1]. À la fin de ce processus, toutes les classes d'occupation du sol discriminées ont servi à la préparation des missions de terrains de collecte d'échantillon de site d'entraînement et de validation.

Tableau 1. Indices spectraux

| Indices spectraux | Codification | Formule |
|--|--------------|--|
| Indice de végétation par différence normalisée | NDVI | $(N - R)/(N + R)$ (Eq.1) |
| Indice de rapport hydrique | WRI | $(G+R)/(N+ S1)$ (Eq.2) |
| Indice d'eau de différence normalisée modifiée | MNDWI | $(G - S1)/(G + S1)$ (Eq.3) |
| Indice de différence normalisé de l'eau | NDWI | $(G - N)/(G + N)$ (Eq.4) |
| Indice basé sur l'indice des zones bâties | IBI | $(((((S1 - N)/(S1 + N)) - ((N - R) \times (1.0 + L)/(N + R + L)) + ((G - S1)/(G + S1)))/2.0)) / (((((S1 - N)/(S1 + N)) + ((N - R) \times (1.0 + L)/(N + R + L)) + ((G - S1)/(G + S1)))/2.0))$ (Eq.4) |
| Indice de différence normalisé des sols nus | NDBSI | $((R + S1) - (N + B)) / ((R + S1) + (N + B))$ (Eq.5) |
| Indice de différence normalisée des zones bâties | NDBI | $(S1 - N)/(S1 + N)$ (Eq.6) |

Avec R = bande rouge; B = bande bleue; G = bande verte; N = bande NIR; S1 = bande SWIR; L = 0.5

4.3 MISSION DE TERRAIN ET JEU DE DONNÉES DES SITES D'ENTRAÎNEMENT

Des missions de terrain ont été organisées afin de collecter des données sur les sites d'entraînement. Le but principal était de visiter un nombre significatif de parcelles sélectionnées en fonction des différentes unités d'occupation du sol discriminées. Dans un premier temps, plus d'une centaine de points de contrôle ont été identifiés à partir de Google Earth puis validés et complétés sur le terrain. Par la suite, toutes les classes inattendues ou anormalement discriminées ont été localisées à partir de leurs coordonnées géographiques, puis visitées pour validation et mise à jour selon les observations de terrain. L'ensemble des points correspondant aux unités d'occupation du sol validées, a été enregistré. Ces données ont été traitées, vectorisées dans un environnement SIG puis importées sur la plateforme cloud Google Earth Engine (GEE) en codifiant les étiquettes des différentes classes identifiées. Le jeu de données obtenu a été subdivisé en deux catégories: 80 % des échantillons ont été utilisés pour l'apprentissage des modèles, tandis que les 20 % restants ont servi à la validation

4.4 CLASSIFICATION SUPERVISÉE À L'AIDE DE L'APPRENTISSAGE AUTOMATIQUE

4.4.1 PRÉSENTATION DES ALGORITHMES

- **Deep Forest (DF)** est un algorithme d'apprentissage profond développé par Zhi-Hua Zhou et Ji Feng en 2017 dans le domaine de l'apprentissage automatique. Sa structure d'empilement est similaire à celle d'un réseau de neurones multicouche sauf que chaque couche de la DF contient des Random Forest (RF) au lieu de neurones. DF est simple à former en raison d'un très petit nombre d'hyperparamètres.
- **Random Forest (RF)** est un algorithme développé par [25] se fondant sur un ensemble d'arbres de décision. L'optimisation du RF repose sur un ensemble de paramètres parmi lesquels, le nombre d'arbres dans la forêt, la profondeur maximale des arbres, le nombre minimum d'échantillons nécessaires pour diviser un nœud ainsi que le nombre de caractéristiques à tester à chaque division.
- **Extra Gradient Boost (XGBoost)** est un algorithme d'apprentissage supervisé, développé par [26], qui repose sur la méthode de Gradient Boosting, une approche largement utilisée dans les tâches de classification et de régression [27]. Il s'agit d'une méthode d'ensemble qui vise à construire un modèle puissant en combinant plusieurs modèles de base, généralement des arbres de décision, tout en corrigeant les erreurs des modèles précédents de manière itérative [28]. La construction et l'optimisation de XGBoost sont influencées par plusieurs paramètres clés. Parmi ceux-ci, le nombre d'arbres, le taux d'apprentissage, la profondeur des arbres et enfin, le paramètre gamma [26]
- **Extra Trees (ET)** est un algorithme d'apprentissage supervisé, proposé par [29], qui s'appuie sur la méthode des forêts aléatoires, une technique d'assemblage largement utilisée pour les tâches de classification et de régression [25]. Contrairement à d'autres approches d'ensembles telles que les arbres de décision classiques ou les méthodes de boosting, Extra Trees construit des arbres de décision de manière aléatoire, en exploitant la diversité dans la construction de ces arbres pour optimiser les performances du modèle global. D'après [29], l'optimisation du modèle Extra Trees repose sur plusieurs paramètres clés dont le nombre d'arbres, la profondeur maximale des arbres ainsi que le nombre minimal d'échantillons par feuille
- **Réseau neuronal convolutif (CNN)** représente une forme particulière de réseaux de neurones artificiels à propagation avant. Très répandus dans des domaines tels que la reconnaissance d'images, la vidéo, le traitement automatique du langage naturel ou encore les systèmes de recommandation, les CNN se classent parmi les architectures les plus performantes en apprentissage automatique. D'après [30], un CNN comprend une couche d'entrée, une couche de sortie, ainsi que plusieurs couches cachées. Ces couches

cachées incluent généralement des couches convolutionnelles, des couches de regroupement (pooling), des couches entièrement connectées, et parfois des couches de normalisation [31].

- **Classification and Regression Trees (CART)** proposée par [32], constitue une technique statistique permettant de construire des modèles prédictifs sous forme d'arbres, utilisables aussi bien pour la régression que pour la classification. La construction de CART nécessite la définition de divers paramètres présentés par [32] parmi lesquels la profondeur maximale de l'arbre qui est le paramètre de réglage le plus important dans CART. Ce dernier détermine la complexité du modèle.

4.4.2 CLASSIFICATION DES UNITÉS D'OCCUPATION DU SOL

Cette phase a débuté par la mise en place du modèle DF qui a nécessité l'utilisation de trois algorithmes Extreme Gradient Boosting (XGB), Random Forest (RF) et Extra Tree (ET). Ces derniers ont été utilisés comme classificateurs arborescents pour la construction du modèle DF. En fonction du type du classificateurs arborescents, c'est au total trois modèles DF, à savoir DF-XGB, DF-RF et DF-ET qui ont été développés avec des paramètres optimaux afin de garantir une classification optimale par pixels des unités d'occupation du sol. Ensuite le meilleur de ces modèles DF a été comparé à quatre (04) classificateurs conventionnels (CNN; RF; XGB et CART) qui sont couramment utilisés dans les études d'occupation du sol afin d'apprécier la performance de l'algorithme DF au regard des critères de précision. Ces algorithmes conventionnels ont été sélectionnés fort de leur efficacité dans la classification des unités d'occupations du sol ([33], [4], [34], [3]). Enfin la carte de l'occupation du sol a été obtenu à l'aide du meilleur modèle. Les paramètres de chaque modèle DF s'est appuyé suivant les paramètres des classificateurs arborescents. L'implémentation de ces algorithmes a été effectué dans un environnement python via Google Colab à l'aide de la bibliothèque open source Scikit-learn qui est réputée en Machine Learning [35]. Pour l'optimisation des algorithmes, tous les paramètres ont été identifié à l'aide de l'approche essai-erreur. Concernant le modèle Random Forest, le nombre d'arbres a été initialement fixé à 100, puis testé pour des valeurs allant de 150 à 1000. La profondeur maximale a été fixé à une valeur de 10, puis ajustée en fonction des résultats obtenus avec des valeurs testées entre 5 et 30. Le nombre minimal d'échantillons requis pour diviser un nœud, a été initialement fixé à 2 et testé pour des valeurs comprises entre 2 et 10. Le nombre minimal d'échantillons par feuille a été ajusté entre 1 et 5. Enfin, le nombre de caractéristiques à considérer lors de la recherche de la meilleure division a été laissé à sa valeur par défaut et testé pour différentes configurations. Concernant les paramètres CART, la valeur de la profondeur maximale a été testé de 1 à 20 pour 8 sous-ensembles d'échantillons d'entraînement en définissant les autres de ses paramètres à partir de leur valeur par défaut (par exemple, les plis de validation croisée et le nombre minimum d'échantillons tous deux définis sur la valeur par défaut de 10). Pour le Random Forest, le nombre d'arbres dans la forêt a été testé de 100 à 1000 et la profondeur maximale des arbres de 10 à 100. Le reste des paramètres ont été définis par leur variables par défaut. Quant au modèle XGBoost (XGB), le nombre d'arbres a initialement été fixé à 100 avant d'être testé pour des valeurs comprises entre 150 et 1000. Le taux d'apprentissage a été déterminé à 0,1 et il a été réduit de 0,001 lorsque les performances obtenues ne répondaient pas aux critères de satisfaction. La profondeur des arbres a , quant à elle, été fixée à une valeur initiale de 6 puis ajustée en fonction des résultats expérimentaux obtenus au cours de l'entraînement. Les autres paramètres du modèle ont été laissés à leurs valeurs par défaut. Concernant le réseau de neuronal convolutif (CNN), plusieurs paramètres ont été ajustés pour maximiser ses performances. Le nombre de couches convolutionnelles a été initialement fixé à 3 puis testé pour des valeurs comprises entre 5 et 10. Le nombre de filtres dans chaque couche a été ajusté avec des valeurs testées entre 32 et 512 en fonction de la complexité des données. Le taille du noyau des convolutions a été fixé à 3×3 au départ puis testé pour des tailles variantes entre 5×5 et 9×9 . Le taux d'apprentissage a été fixé à 0.001 initialement et ajusté de manière dynamique avec une réduction de 0.0001 lorsque les performances ne répondaient pas aux attentes. Le Momentum a été fixé à 0.9 et la fonction d'activation utilisée dans les couches convolutionnelles a été ReLU, tandis que pour la couche de sortie, une fonction softmax a été utilisée pour les tâches de classification multi-classes. Le pooling a été appliqué après chaque couche convolutionnelle avec une taille de pooling de 2×2 , et la technique de dropout a été introduite avec un taux de 0.5 pour éviter le surapprentissage. Le nombre d'époques a été initialement fixé à 50 puis ajusté en fonction de la convergence du modèle. Tous les paramètres de chaque modèle ont été modifiés de manière progressive dans le but d'atteindre des performances optimales en procédant à des ajustements successifs basés sur l'analyse des résultats obtenus à chaque étape.

4.5 CLASSIFICATION SUPERVISÉE À L'AIDE DE L'APPRENTISSAGE AUTOMATIQUE

Pour évaluer la qualité et les performances des modèles développés, les coefficients de Kappa et d'Exactitude ont été utilisés auxquels sont ajoutés trois autres mesures de qualité dont les critères de Précision, de Rappel et du Score F1 sélectionnés sur la base d'un examen approfondi de la littérature ([33], [4], [36], [1], [37]). La précision se définit comme le rapport entre les cas classés positifs qui ont été correctement classés selon la formule (Eq.7). Concernant le critère du Rappel, il est déduit de l'équation (Eq.8), et se définit comme la proportion des cas correctement prédits par le modèle. Quant au score F1 obtenu à l'aide de l'équation mathématique (Eq.9), il est la combinaison du résultat de la prédiction de précision et de rappel. Le tableau ci-dessous présente la formulation mathématique des trois critères additifs.

Tableau 2. Critère d'évaluation de la précision des modèles

| Critère | Formulation mathématique |
|-----------|---|
| Précision | $(\text{Vrai Positif})/(\text{Vrai Positif}+\text{Faux Positif})$ (Eq.7) |
| Rappel | $(\text{Vrai Positif})/(\text{Vrai Positif}+\text{Faux Negatif})$ (Eq.8) |
| Score F1 | $(\text{Précision}\times\text{Rappel})/(\text{Précision}+\text{Rappel})$ (Eq.9) |

5 RÉSULTATS

5.1 CORRECTION DES IMAGES SENTINEL-1

La figure 3 présente les résultats obtenus à l'issue de la phase de prétraitement des images Sentinel-1. Une comparaison entre les images non corrigées (bruitées) et celles corrigées en polarisation VH, montre une différence nette de la qualité des images corrigées. Plusieurs zones de l'image bruitées (A) qui ont présentés des chatoiements ont été corrigées à l'issue des phases de suppression des bruits à l'aide des filtres particulièrement celui de Lee Amélioré. La qualité des images corrigées (B) montre que le filtre de Lee Amélioré de taille 5x5 appliqué à aux images bruitées a eu un effet positif. En effet, ce filtre a lissé les zones homogènes, et a entraîné une diminution de l'aspect granulaire du chatoiemement présent sur l'image bruitée comme le montrent certaines zones des images bruitées (A) et corrigées (B).

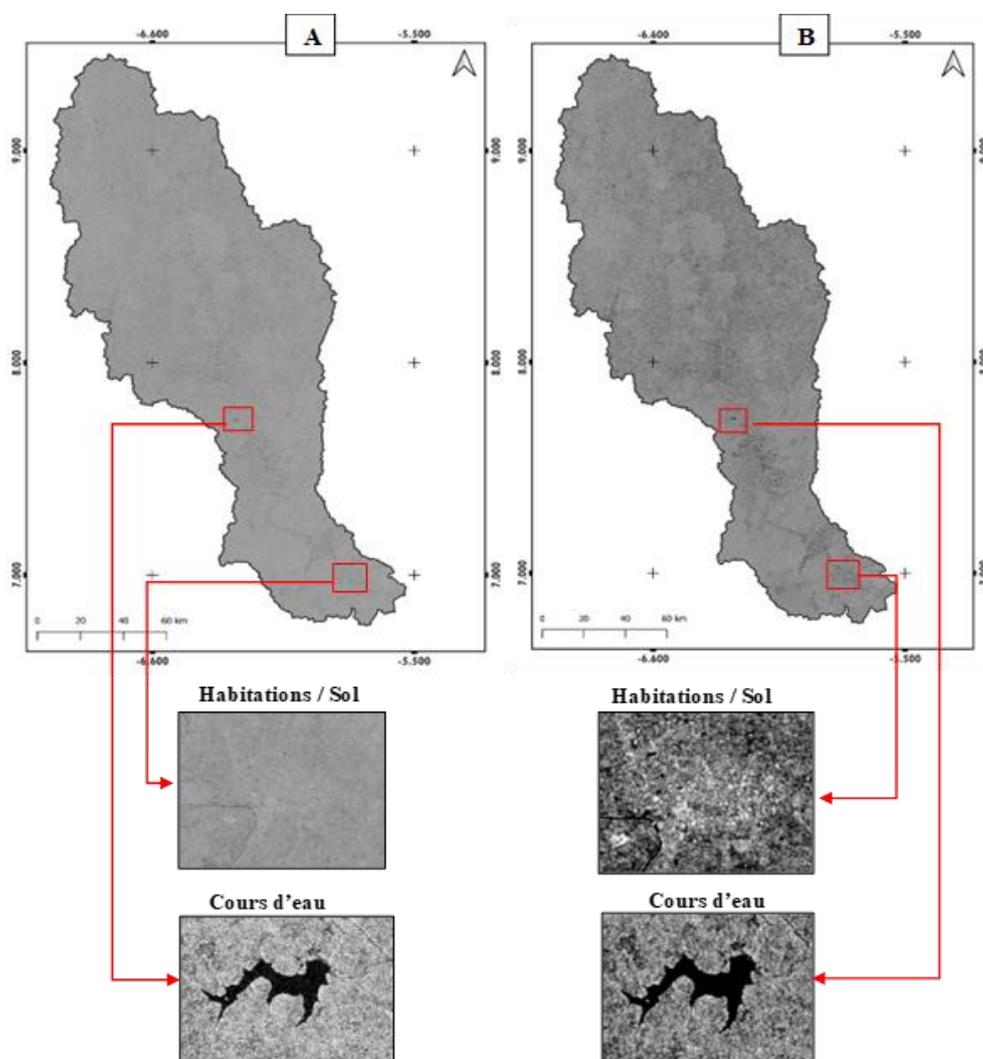


Fig. 3. Prétraitement des images Sentinel-1. (A): Image bruitée et (B): Image corrigée

5.2 DISCRIMINATION DES UNITÉS D'OCCUPATION DU SOL

La classification non supervisée appliquée à l'ensemble de la zone d'étude a permis de distinguer dix-huit (18) classes, identifiées à l'aide de palettes de couleurs attribuées aléatoirement. Les figures 4.a et 4.b illustrent la répartition spatiale de ces différentes classes. L'analyse de ces cartes met en évidence la présence de plusieurs entités paysagères bien distinctes, notamment les plans d'eau, les cours d'eau, les zones humides, les zones de culture agricole ainsi que les habitats humains. Toutefois, un certain nombre de classes générées par la classification n'ont pas pu être formellement étiquetées faute de correspondance explicite avec des éléments connus du terrain. Ces classes non identifiées ont été temporairement désignées comme Unité 1, Unité 2, Unité 3, Unité 5, Unité 6, Unité 7, Unité 8, Unité 9, Unité 11, Unité 13 et Unité 15. Par ailleurs, la classe correspondant aux zones de culture agricole a, dans certains cas, pu être associée à la culture de la canne à sucre, notamment dans certaines portions du bassin versant (Figure 4.a). Toutefois, dans d'autres zones, cette classe demeure difficile à différencier des unités adjacentes, en raison d'une faible distinction spectrale ou d'une hétérogénéité interne élevée.

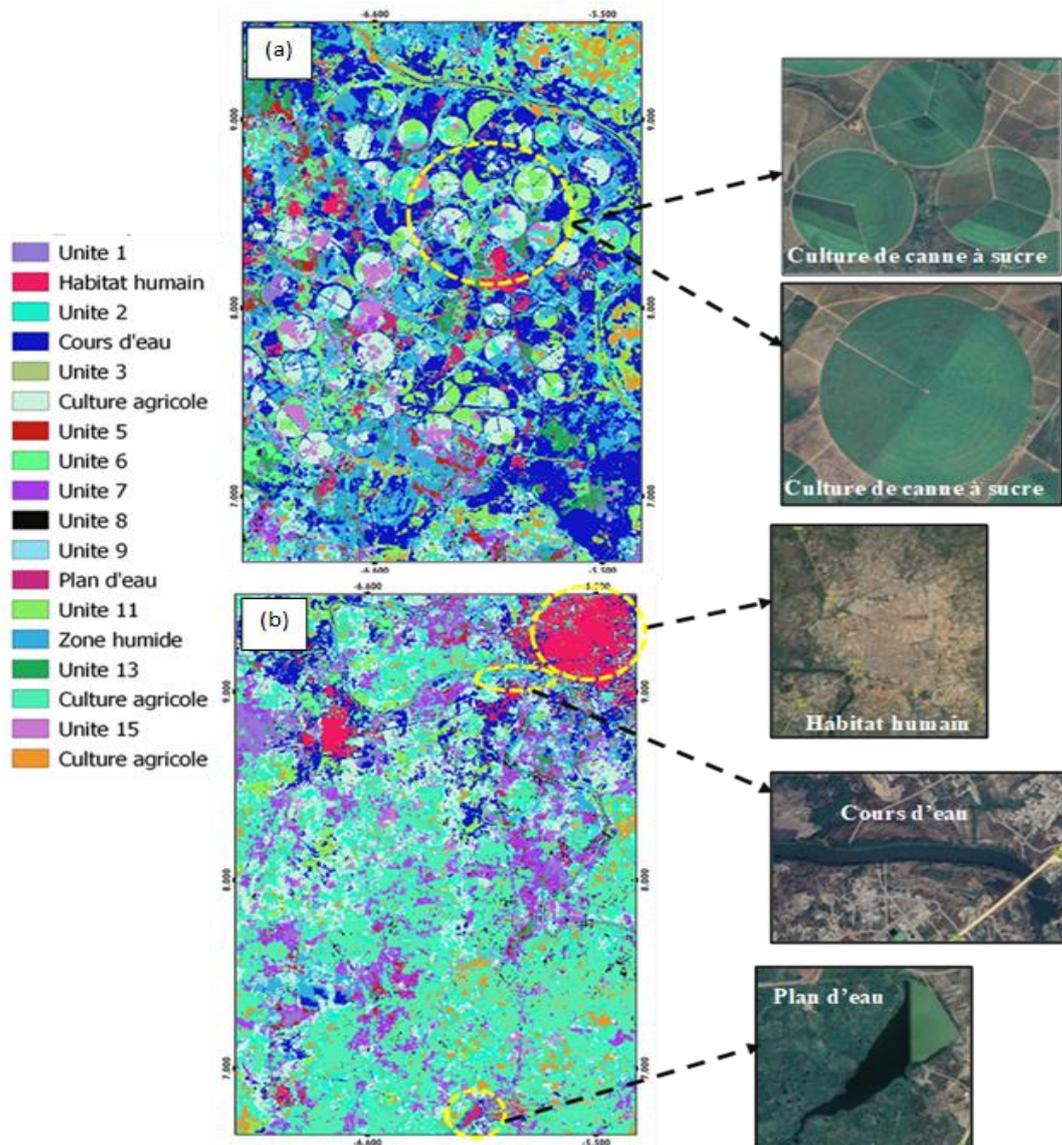


Fig. 4. Unités d'occupation détectées par classification non supervisées

Par ailleurs, plusieurs classes ont été aussi mises en évidence de manière distincte à partir des indices spectraux, dont la figure 5 illustre la distribution spatiale sur l'ensemble de la zone d'étude. L'analyse de ces figures révèle une répartition hétérogène des valeurs spectrales traduisant la diversité des caractéristiques biophysiques et anthropiques du territoire. Cette variabilité spatiale témoigne notamment de la présence d'une activité anthropique intense, de plans d'eau, de zones humides ainsi que de formations végétales allant d'une couverture dense à des zones arides, réparties sur l'ensemble du bassin versant. En revanche, certaines classes d'occupation du sol, non détectées de manière satisfaisante par les seuls indices spectraux, ont nécessité une validation et un étiquetage complémentaire

à travers des missions de terrain. Ces observations *in situ* ont permis de confirmer la nature de ces unités et d'affiner leur classification. La nomenclature adoptée pour l'identification des différentes classes d'occupation du sol s'appuie sur les référentiels proposés par le Centre d'Information Géographique et du Numérique (CIGN), en cohérence avec les classifications utilisées dans les études antérieures portant sur le territoire national et la sous-région ouest-africaine. Ainsi, les unités identifiées sont considérées comme suit:

- forêts denses, les formations naturelles de type primaire, peuplement fermé avec des arbres et des arbustes atteignant différentes hauteurs entre 5 et 50 m;
- forêts marécageuses, les formations forestières de couverture supérieure à 30 %, établies sur des sols hydromorphes à proximité de cours d'eau;
- plantations forestières, les parcelles boisées ou régénération environnementale dont la hauteur des arbres est supérieure à 5 m et le taux de couverture est supérieure à 30 %;
- formations arbustives, les formations végétales constituée d'arbustes, de moins de 5 m de haut;
- hévée, les plantations d'hévéas de 30 m de haut à feuilles caduques;
- plantations d'espèces de palmiers, les familles des cocotiers de 5 à 25 m de haut, surmontées d'une large couronne de conifères;
- aménagements agricoles et autres cultures, les superficies des autres terres avec des cultures indifférenciées et des vergers divers, y compris les cultures de plaine et les jeunes jachères âgées de 3 à 7 ans;
- plans d'eau et cous d'eau, des groupes de zones de dépression contenant de l'eau sous la forme d'un réservoir et d'un flux d'eau interconnecté (lagune, réservoir) et Réseau hydrographique linéaire interconnecté, se dirigeant vers un plan d'eau;
- habitats/sols nus, les zones résultant des activités humaines, autres qu'agricoles, pour l'urbanisation et les constructions diverses;

Finalement, c'est 739 échantillons qui ont été collectés, identifiés et validés traduisant seize (16) classes d'occupation du sol dans la zone d'étude. Les étiquettes associées à ces différentes classes ont été codifiées comme indiqué dans le tableau 3

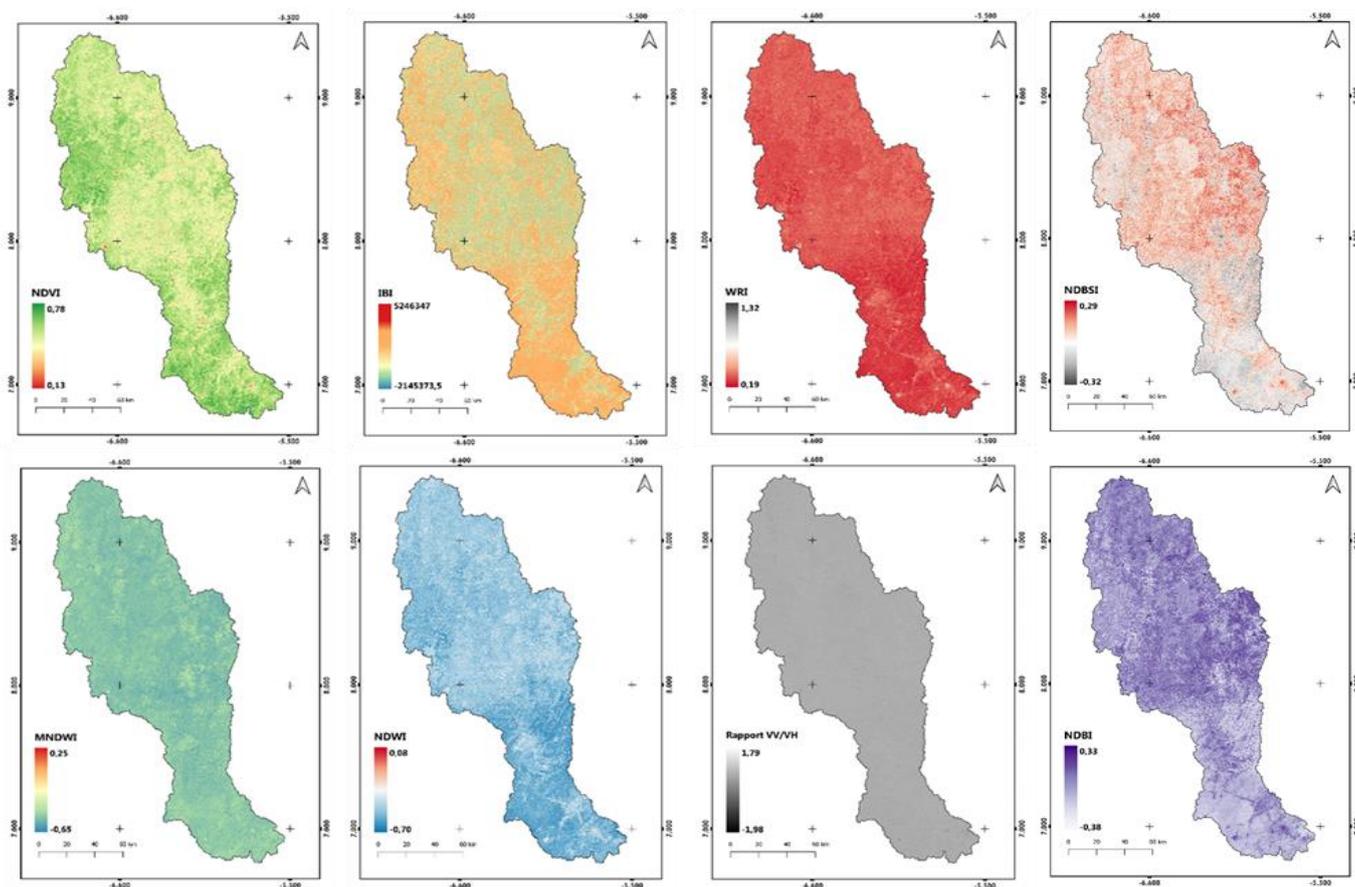


Fig. 5. Indices spectraux calculés

Tableau 3. Échantillon de données sélectionnées dans cette étude

| N° | Unité d'occupation du sol | Codification | Échantillons |
|------------------------|---|--------------|--------------|
| 1 | Aménagements agricoles /Autres cultures /Vergers Jachères | AG | 87 |
| 2 | Anacarde | AN | 152 |
| 3 | Arbor cultures /Plantations fruitières | AC | 14 |
| 4 | Cacao- Café | CAC | 31 |
| 5 | Forêt claire | FC | 38 |
| 6 | Forêt dense | FD | 23 |
| 7 | Forêt galerie | FG | 14 |
| 8 | Formations arbustives Fourrés | FA | 19 |
| 9 | Habitats humains | HAB | 92 |
| 10 | Hévéa | HE | 22 |
| 11 | Palmeraie | PA | 14 |
| 12 | Plan d'eau | PE | 47 |
| 13 | Plantation de Canne à sucre | PC | 112 |
| 14 | Plantations forestières Reboisement | PF | 21 |
| 15 | Savane arborée | SA | 33 |
| 16 | Zones marécageuses | ZM | 20 |
| Total des échantillons | | | 739 |

5.3 CLASSIFICATION DES UNITÉS D'OCCUPATION PAR LE DEEP LEARNING

- Construction et optimisation des modèles

Les modèles développés ont été optimisés suivant plusieurs paramètres dont les meilleures valeurs sont consignées dans le tableau 5.

Tableau 4. Valeurs optimales des paramètres des modèles développés

| N° | Modèle | Paramètres | Valeurs | Meilleures valeurs | |
|----|--------|---------------|-----------------------------|-------------------------------|-----|
| 1 | DF-ET | DF | Max_layers | 100, 200, 300, 500, 600, 1000 | 500 |
| | | | Random_state | 0, 1, 2,3 | 0 |
| | | ET | n_estimateur | 100, 200, 300,400,500 | 50 |
| | | | n_folds | 10, 20, 30, 50,60,80,100 | 10 |
| | | | max_depth | 10, 20,30,40,50,60, 80, 100 | 100 |
| 2 | DF-RF | DF | Max_layers | 100, 200, 300, 500, 600, 1000 | 500 |
| | | | Random_state | 0, 1, 2,3 | 0 |
| | | RF | n_estimateur | 50, 100, 200, 300,400,500 | 50 |
| | | | n_folds | 10, 20, 30, 50,60,80,100 | 50 |
| | | | max_depth | 10, 20,30,40,50,60 | 50 |
| 3 | DF-XGB | DF | Max_layers | 100, 200, 300, 500, 600, 1000 | 500 |
| | | | Random_state | 0, 1, 2,3 | 0 |
| | | XGB | n_estimateur | 100, 200, 300,400,500 | 300 |
| | | | n_folds | 10, 20, 30, 50,60,80,100 | 50 |
| | | | Learning_rate | 0.001, 0.01, 0.1 | 0.1 |
| | | max_depth | 10, 20,30,40,50,60 | 50 | |
| 5 | CNN | kernel_size | 3, 5, 6, 7, 9 | 3 | |
| 6 | RF | n_estimateur | 50, 100, 200, 300,400,500 | 300 | |
| | | max_depth | 10, 20,30,40,50,60 | None | |
| 7 | XGB | n_estimators | 20, 40, 50, 60, 100 | 100 | |
| | | Learning_rate | 0.001, 0.01, 0.1 | 0.1 | |
| | | max_depth | 5, 10, 12, 15, 20, 30, 50 | 5 | |
| | | | | | |
| 8 | CART | n_estimateur | 10, 20, 50,60,100 | 50 | |
| | | n_folds | 10, 20, 30, 50 | 10 | |
| | | max_depth | 10, 20,30,40,50,60, 80, 100 | 100 | |

Le modèle DF-ET a obtenu ses meilleures performances avec une profondeur maximale de cascade (Max_layers) fixée à 500, une valeur de Random_state de 0, un nombre d'estimateurs (n_estimateur) de type Extra Trees fixé à 50, une validation croisée à 10 plis et une profondeur maximale des arbres (max_depth) égale à 100. Concernant, le modèle DF-RF, il a présenté une configuration similaire en termes de profondeur de cascade et de reproductibilité mais s'est distingué par un nombre plus élevé de plis pour la validation croisée, estimé à 50 et une profondeur maximale des arbres modérée à 50. Pour le modèle DF-XGB, les paramètres optimaux incluent également une profondeur de cascade de 500 et un Random_state de 0. DF-XGB s'est caractérisé par l'utilisation de 300 estimateurs de type XGBoost, un taux d'apprentissage (learning_rate) relativement élevé fixé à 0.1 avec 50 plis de validation croisée et une profondeur maximale des arbres de 50. Concernant les classificateurs conventionnels, le modèle CNN a disposé d'une configuration suffisante avec un noyau de convolution optimal d'une taille (kernel_size) de 3. Quant au modèle RF, il a montré une configuration assez robuste avec 300 estimateurs et une profondeur d'arbre non limitée (max_depth = None). Le modèle XGB (XGBoost), de son côté, a atteint ses meilleurs résultats avec 100 estimateurs, un learning_rate de 0.1 et une faible profondeur maximale de 5. Enfin, le modèle CART a été optimisé avec 50 estimateurs, une validation croisée à 10 plis et une profondeur maximale des arbres fixée à 100.

- Unités d'occupation du sols discriminées par les algorithmes

Seize (16) classes dont Aménagements agricoles /Autres cultures et jachères non différenciées, Anacarde, Arbor cultures /Plantations fruitières, Cacao-café, Forêt claire, Forêt dense, Forêt galerie, Formations arbustives Fourrés, Habitats humains, Hévéa, Palmeraie, Plan d'eau, Plantation de Canne à sucre, Plantations forestières et reboisement, Savane arborée, Zones marécageuses ont été identifiées dans des proportions différentes sur le bassin versant de la Marahoué par tous les modèles d'apprentissage automatique Deep Forest et classificateurs conventionnels développés dans cette étude. Les résultats des performances de ces modèles sont consignés respectivement dans le tableau 5.

Tableau 5. Performances des modèles Deep Forest

| | DF-ET | | | DF-RF | | | DF-XGB | | |
|------------|-------|------|-----|-------|------|-----|--------|------|-----|
| | PR | RE | F1 | PR | RE | F1 | PR | RE | F1 |
| AG | 92% | 84% | 88% | 92% | 83% | 87% | 98% | 96% | 98% |
| AN | 97% | 95% | 96% | 97% | 95% | 96% | 98% | 95% | 96% |
| AC | 67% | 88% | 76% | 67% | 88% | 76% | 99% | 99% | 98% |
| CAO | 83% | 83% | 83% | 82% | 82% | 82% | 92% | 92% | 93% |
| FC | 78% | 88% | 83% | 77% | 88% | 82% | 95% | 85% | 84% |
| FD | 87% | 91% | 89% | 87% | 87% | 87% | 89% | 93% | 91% |
| FG | 62% | 92% | 71% | 68% | 81% | 74% | 84% | 98% | 89% |
| FA | 66% | 86% | 75% | 66% | 84% | 74% | 80% | 85% | 82% |
| HAB | 95% | 96% | 96% | 94% | 96% | 95% | 99% | 99% | 99% |
| HE | 78% | 95% | 86% | 84% | 93% | 89% | 98% | 89% | 96% |
| PA | 75% | 100% | 86% | 71% | 100% | 83% | 98% | 100% | 85% |
| PE | 98% | 99% | 99% | 98% | 99% | 99% | 97% | 100% | 98% |
| PC | 99% | 98% | 99% | 99% | 98% | 99% | 99% | 99% | 99% |
| PF | 80% | 83% | 81% | 78% | 86% | 82% | 97% | 92% | 98% |
| SA | 74% | 77% | 75% | 73% | 74% | 74% | 99% | 98% | 92% |
| ZM | 63% | 84% | 72% | 66% | 79% | 72% | 80% | 84% | 82% |

AG: Aménagements agricoles /Autres cultures /Jachères non différenciées; AN: Anacarde; AC: Arbor cultures /Plantations fruitières; CAO: Cacao-café; FC: Forêt claire; FD: Forêt dense; FG: Forêt galerie; FA: Formations arbustives Fourrés; HAB: Habitats humains; HE: Hévéa; PA: Palmeraie; PE: Plan d'eau; PC: Plantation de Canne à sucre; PF: Plantations forestières et reboisement; SA: Savane arborée; ZM: Zones marécageuse

L'analyse des résultats du tableau 5 montre un niveau très élevé de concordance entre la vérité de terrain et les classes d'occupation du sol prédites par tous les modèles Deep Forest développés. En effet, ces derniers ont réussi à discriminer toutes les classes d'occupation du sol avec un taux de réussite qui varie de 62% à 100% au regard des indices statistiques. Les zones d'habitats humains (HAB) ont été discriminées avec un taux de réussite qui varie de 94% à 99%. Quant aux zones humides notamment les plans d'eau (PE), ils ont été restitués à plus de 97% de succès, tandis que les zones marécageuses (ZM) ont été discriminées avec un taux de réussite allant de 63% à 80% pour la précision, de 79% à 84% pour l'indice de Rappel et de 72% à 82% pour le score F1. Les cultures pérennes notamment le binôme Cacao-Café (CAO), elles ont été restituées avec un taux qui varie de 82% à 92% pour la précision, de 82% à 92% pour l'indice de Rappel et de 82% à 93% pour le score F1. L'hévéa (HE) et le palmier (PA) qui sont aussi cultivés dans le secteur d'étude, ont été discriminés avec plus de 71% en précision, plus de 89% en Rappel et plus de 86% en score F1. À ceux-ci, s'ajoute l'anacarde (AN) qui a obtenu une reconnaissance optimale avec un taux de plus de 95% en précision comme en Rappel et en score F1. Quant aux formations forestières

et arbustives (Forêt claire, forêt galerie, Forêt dense, Plantation forestière, formations arbustives et savane arborées), elles ont été suffisamment restituées par les modèles DF avec un taux de réussite qui varie de 62% à 99% en précision, de 77% à 98% pour l'indice de Rappel et de 71% à 98% pour le score F1. Les autres cultures et jachères non différenciées (AG) ont été discriminées dans l'ensemble avec un taux de réussite qui varie de 92% à 98% en précision, de 83% à 96% pour l'indice de Rappel et de 87% à 98% pour le score F1. Parmi les 16 classes d'occupations du sol extraites des images satellitaires et identifiées par les modèles DF, la formation arbustive (FA), la forêt dense (FD), le binôme Cacao-Café (CAO), l'hévéa (HE), la forêt claire (FC), la savane arborée (SA), les plantations fruitières (AC) et les zones marécageuses (ZM) ont eu des taux de précision qui varie entre 63% à 78%, un indice de Rappel qui varie de 77% à 88%, un score F1 qui varie de 72% à 86 en général de la part des modèles DF-RF et DF-ET. Cette disparité au niveau de la classification met en évidence des erreurs de reconnaissances de ces classes de la part des modèles cités. Un tel résultat qui pourrait s'expliquer par l'hétérogénéité des formations observées traduite par une ressemblance au niveau de leur réponse spectrale. Finalement, le classificateur DF-XGB a surpassé les autres classificateurs DF développés (DF-RF et DF-ET) dans la reconnaissance des classes d'occupation de sols avec un taux de réussite qui varie de 80% à 99% pour la précision, de 85% à 100% pour l'indice de Rappel et de 82% à 99% pour le score F1. Au niveau des performances de précision qui sont traduites par le coefficient de Kappa, d'Exactitude, de Rappel global et de F1 global, la figure 6 présente les résultats obtenus. L'analyse de cette figure montre que le coefficient de Kappa, de l'indice d'Exactitude, l'indice Rappel global et le score F1 global des modèles sont respectivement 92,44%, 93,81%, 93,81% et 93,81% pour le modèle DF-ET; 91,86%, 93,34%, 93,33% et 92,04% pour le modèle DF-RF; 93%, 95%, 94% et 94% pour le modèle DF-XGB. Ces résultats traduisent que plus de 91% des classes d'occupations de sol sont bien identifiées et par conséquent bien classées. Et l'erreur marginale commise par ces modèles est moins de 9%. Une comparaison de ces performances montre que DF-XGB constitue le meilleur classificateur. Ce dernier sera comparé au modèles CNN, XGB, RF et CART.

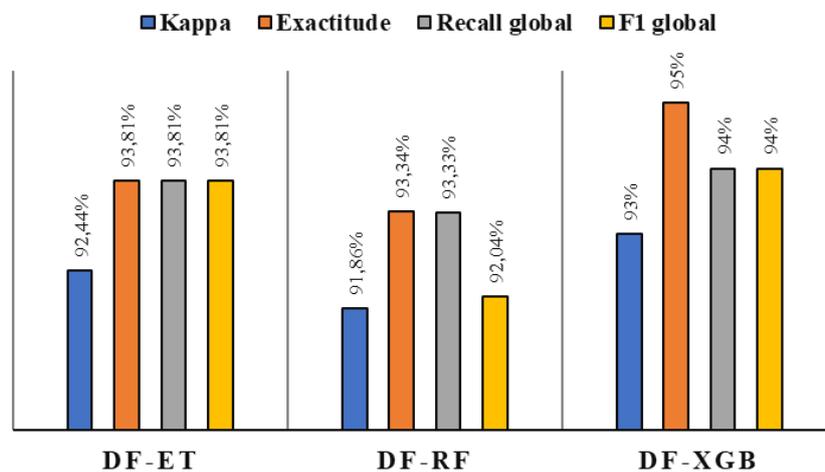


Fig. 6. Distribution graphique des performances des modèles

- Etude comparative entre DF-XGB et classificateurs conventionnels

Les performances des modèles DF-XGB, CNN, XGB, RF et CART sont consignées dans le tableau 6.

Tableau 6. Performances comparatives entre DF-XGB et les autres classificateurs

| Classes | DF-XGB | | | CNN | | | XGB | | | RF | | | CART | | |
|---------|--------|------|-----|-----|-----|-----|-----|------|-----|-----|------|-----|------|-----|-----|
| | PR | RE | F1 | PR | RE | F1 | PR | RE | F1 | PR | RE | F1 | PR | RE | F1 |
| AG | 98% | 96% | 98% | 86% | 62% | 72% | 88% | 79% | 83% | 97% | 96% | 96% | 97% | 96% | 90% |
| AN | 98% | 95% | 96% | 89% | 83% | 85% | 96% | 94% | 95% | 98% | 94% | 96% | 97% | 90% | 92% |
| AC | 99% | 99% | 98% | 15% | 45% | 22% | 70% | 78% | 74% | 96% | 100% | 98% | 91% | 93% | 92% |
| CAO | 92% | 92% | 93% | 35% | 49% | 40% | 84% | 71% | 77% | 89% | 91% | 90% | 85% | 91% | 86% |
| FC | 95% | 85% | 84% | 26% | 17% | 21% | 79% | 74% | 76% | 94% | 53% | 68% | 94% | 81% | 80% |
| FD | 89% | 93% | 91% | 12% | 50% | 20% | 88% | 93% | 91% | 33% | 98% | 49% | 87% | 85% | 87% |
| FG | 84% | 98% | 89% | 56% | 56% | 45% | 61% | 70% | 65% | 77% | 78% | 87% | 81% | 91% | 81% |
| FA | 80% | 85% | 82% | 45% | 35% | 60% | 49% | 74% | 59% | 55% | 83% | 70% | 78% | 81% | 77% |
| HAB | 99% | 99% | 99% | 90% | 96% | 93% | 93% | 96% | 94% | 97% | 99% | 98% | 98% | 99% | 99% |
| HE | 98% | 89% | 96% | 61% | 44% | 51% | 80% | 89% | 85% | 98% | 88% | 93% | 91% | 87% | 88% |
| PA | 98% | 92% | 85% | 79% | 21% | 33% | 68% | 93% | 78% | 98% | 89% | 94% | 93% | 84% | 81% |
| PE | 97% | 100% | 98% | 97% | 99% | 98% | 96% | 100% | 98% | 96% | 98% | 98% | 95% | 99% | 96% |
| PC | 99% | 99% | 99% | 98% | 97% | 97% | 98% | 96% | 97% | 98% | 98% | 99% | 91% | 99% | 99% |
| PF | 97% | 92% | 98% | 60% | 55% | 45% | 68% | 83% | 74% | 98% | 96% | 97% | 81% | 89% | 91% |
| SA | 99% | 98% | 92% | 36% | 28% | 32% | 53% | 72% | 61% | 99% | 74% | 84% | 89% | 95% | 92% |
| ZM | 80% | 81% | 82% | 55% | 45% | 25% | 69% | 88% | 77% | 51% | 65% | 67% | 78% | 79% | 82% |

AG: Aménagements agricoles /Autres cultures /Jachères non différenciées; AN: Anacarde; AC: Arbor cultures /Plantations fruitières; CAO: Cacao-café; FC: Forêt claire; FD: Forêt dense; FG: Forêt galerie; FA: Formations arbustives Fourrés; HAB: Habitats humains; HE: Hévéa; PA: Palmeraie; PE: Plan d'eau; PC: Plantation de Canne à sucre; PF: Plantations forestières et reboisement; SA: Savane arborée; ZM: Zones marécageuses

L'analyse du tableau 6, montre que DF-XGB surpasse tous les autres classificateurs (CNN, XGB, RF, CART) dans la reconnaissance des 16 classes d'occupation du sol avec un taux qui oscille entre 80% à 100% en Précision comme en indice de Rappel et en score F1. Le classificateur RF est très performant que CNN, XGB et CART dans la reconnaissance des autres cultures et jachères non différenciées, de l'anacarde et des plantations fruitières avec un score F1 respectivement de 96%, 96% et 98% et une précision respective de 97%, 98% et 96%. D'un autre côté, RF est plus performante que (CNN, XGB et CART) dans la discrimination de la classe Cacao-Café, l'habitats humains, l'hévéa et le palmier avec un score F1 respectivement de 90%, 98%, 93%, 94%. Les classificateurs basés sur les arbres ont réussi à distinguer correctement les 16 classes d'occupations du secteur d'étude. Ils se sont même hissés devant les réseaux de neurones convolutifs. Au niveau des performance de précision qui sont traduites par le coefficient de Kappa, d'Exactitude, de Rappel global et de F1 global, le tableau 7 présente les résultats obtenus.

Tableau 7. Distribution statistique des performances des modèles

| Kappa | Exactitude | Rappel | F1 |
|--------|------------|--------|-----|
| DF-XGB | 93% | 95% | 94% |
| CNN | 79 % | 83% | 82% |
| XGB | 89% | 91% | 91% |
| RF | 92% | 81% | 86% |
| CART | 91% | 89% | 88% |

L'analyse du tableau 7 montre que le coefficient de Kappa, l'indice d'Exactitude, l'indice Rappel global et le score F1 global des modèles sont respectivement 93 %, 95 %, 94 % et 94 % pour le modèle DF-XGB; 79 %; 83 %, 82 % et 82 % pour le CNN; 89 %, 91 %, 91 % et 92 % pour XGB; 92 %; 81 %, 86 % et 84 % pour le RF; 91 %, 89 %, 88 % et 89 % pour le modèle CART. Ces résultats traduisent que plus de 90 % des classes d'occupations de sol sont bien identifiées et par conséquent bien classées par les classificateurs basés sur les arbres de décisions (DF-XGB; XGB; RF; CART), soit une erreur marginale commise de 10%. Concernant les CNN, c'est plus de 20% d'erreur marginale commise. C'est à plus de 20% des unités d'occupations ont été mal restituées. Une comparaison de ces performances montre que DF-XGB constitue le meilleur classificateur.

- Carte d'occupation du sol

La carte des classes d'occupations du sol et leur différentes superficies associées ont été générée à l'aide du modèle DF-XGB qui constitue le meilleur classificateur de cette étude. Le tableau 8 présente les superficies des différentes classes d'occupations du sol y compris leurs pourcentages respectifs et la figure 8 présente la répartition spatiale de ces unités d'occupation du sol.

Tableau 8. Superficie des classes d'occupation du sol de la Marahoué en 2018

| N° | Classes d'occupation du sol | Superficies (hectare) | Proportion |
|-------|--|-----------------------|------------|
| 1 | Aménagements agricoles/Autres cultures et jachères non différenciées | 726 827 | 33,90 % |
| 2 | Culture d'anacarde | 525 796 | 24,52 % |
| 3 | Arbor cultures / Plantation fruitière | 3 452 | 0,16 % |
| 4 | Culture de cacao-café | 119 739 | 5,58 % |
| 5 | Forêt claire | 46 161 | 2,15 % |
| 6 | Forêt dense | 191 009 | 8,91 % |
| 7 | Forêt galerie | 26 478 | 1,23 % |
| 8 | Formation arbustive | 2 379 | 0,11 % |
| 9 | Habitat humain | 53 509 | 2,50 % |
| 10 | Culture d'hévéa | 10 007 | 0,47 % |
| 11 | Culture de palmier | 31 760 | 1,48 % |
| 12 | Plan d'eau | 7 030 | 0,33 % |
| 13 | Canne à sucre | 115 513 | 5,39 % |
| 14 | Plantations forestières | 22 816 | 1,06 % |
| 15 | Savane arborée | 253 203 | 11,81 % |
| 16 | Zones marécageuses | 8 388 | 0,39 % |
| Total | | 2 144 066 | 100 % |

L'analyse du tableau 8 et de la figure 7 montre que la distribution des classes d'occupation du sol au niveau du bassin versant de la Marahoué en 2018 est dominée par l'aménagements agricoles, autres cultures et jachères non différenciées qui couvrent près de 726 827 hectares soit 33,90 % de la superficie totale du bassin, ensuite vient la classe anacarde qui couvrent près de 525 796 hectares, soit 24,52 % de la superficie du bassin. Les cultures pérennes notamment, le café et le cacao sont aussi discriminées avec une superficie couverte de 119 739 hectares, soit près de 5,58 % de la superficie totale de la zone d'étude. Auxquelles s'ajoutent la culture d'hévéa et de palmier qui couvrent respectivement 10 007 et 31 760 hectares, soit 0,47 % et 1,48 % de la zone d'étude. La culture de canne à sucre et les plantations fruitières ont une couverture respective de 115 513 hectares et 3 452 hectares soit, respectivement 5,39 % et 0,16 %. Quant à la couverture forestières et arbustives comprenant la forêt claire, la forêt dense, la forêt galerie, la formation arbustive et la plantation forestière, elles couvrent respectivement 46 161 hectares, 191 009 hectares, 26 478 hectares, 26 478 hectares et 22 816 hectares, soit 2,15 %, 8,91 %, 1,23 %, 0,11 % et 1,06 %. La savane arborée est beaucoup représentative à l'échelle du bassin avec 253 203 hectares, soit 11,81 % de la superficie totale de la zone d'étude. Elle constitue la troisième classe très importante en termes de superficie. Au niveau des habitats humains, ils couvrent la zone avec 53 509 hectares, soit 2,50 % de la zone d'étude. Quant aux zones humides comprenant les plans d'eau et les zones marécageuses, elles ont une superficie sur l'ensemble du secteur d'étude respectivement 7 030 hectares et 8 388 hectares, soit 0,33 % et 0,39 %

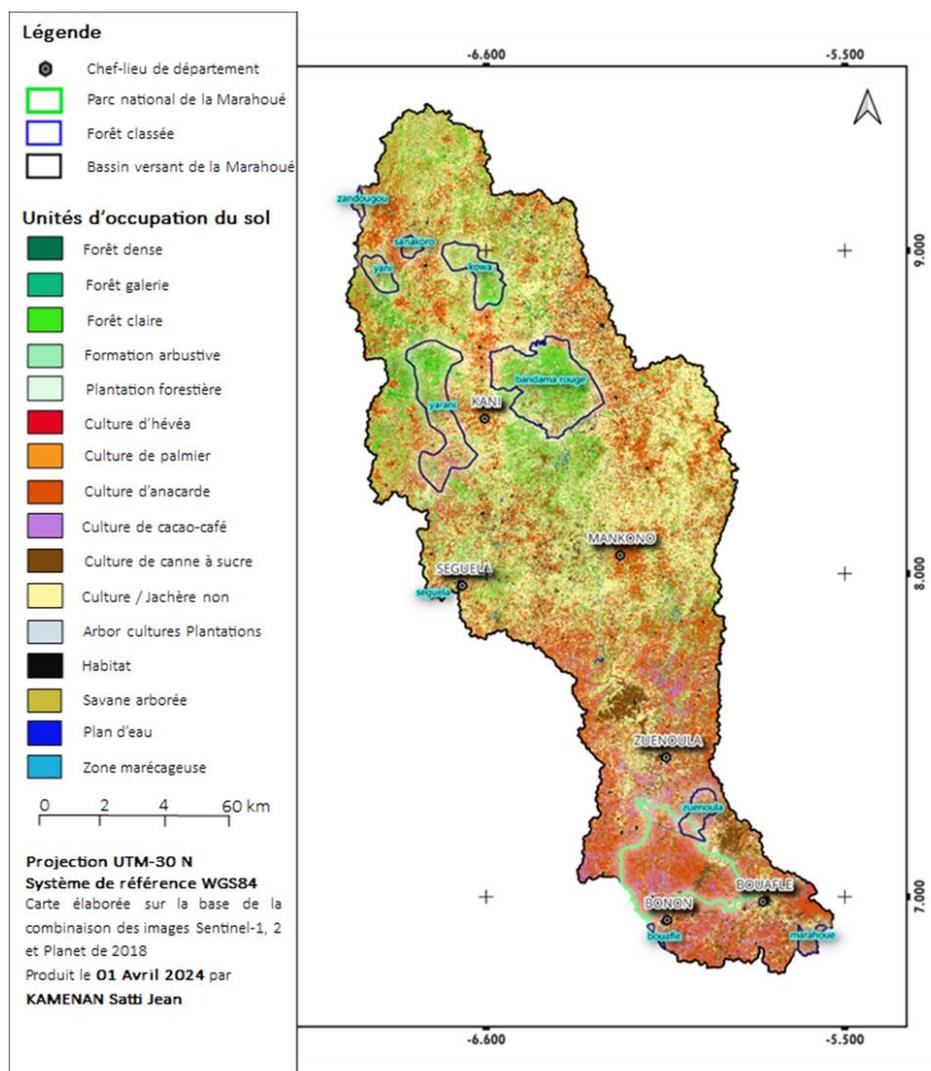


Fig. 7. Carte d'occupation du sol du bassin versant de la Marahoué en 2018

6 DISCUSSIONS

Dans cette étude, des images optiques sentinel-2, Planet Scope et des images radars Sentinel-1, ont été combinées afin de créer une image de multi bandes dérivant des néo canaux et des indices spectraux identifiés à cet effet pour capturer les classes d'occupation de sol dans le bassin versant de la Marahoué. L'algorithme Deep Forest est utilisé comme principal classificateur dont sa construction a nécessité l'utilisation de trois algorithmes usuels Extreme Gradient Boosting (XGB), Random Forest (RF) et Extra Tree (ET) comme classificateurs arborescents afin d'obtenir trois modèles du Deep Forest (DF-XGB; DF-RF; DF-ET) développés puis optimisés. Ces derniers ont été ensuite comparés à quatre (04) autres classificateurs conventionnels (CNN; RF; XGB et CART), couramment utilisés dans les études d'occupation du sol. Les résultats obtenus de cette étude indiquent que les modèles DF ont surclassé les classificateurs conventionnels en termes de précision globale. Pourtant, une analyse détaillée des précisions spécifiques à chaque classe montre que les modèles conventionnels étaient aussi capables d'atteindre des précisions plus élevées dans certaines classes. Si ces classificateurs Deep Learning ont pu rendre compte des classes d'occupations du sol de la Marahoué, plusieurs paramètres y ont contribué notamment, les données de télédétections, la plateforme GEE, les performances intrinsèques de ces modèles.

- Apport de la plateforme GEE et de la combinaison des images multi capteurs

La plateforme GEE semble plus conviviale pour développer des analyses spécifiques grâce à l'interface de programmation facile à utiliser au code JavaScript et python. La disponibilité d'algorithmes avancés et la base de données d'imagerie de télédétection optique et radar qu'offre GEE, font de cet outil une référence dans le domaine du traitement et d'analyse d'images complexes. Selon l'auteur [1], les algorithmes d'apprentissage automatique les plus récents, notamment ceux du Deep Learning peuvent être utilisés dans GEE via l'environnement Python Google Colab. Bien évidemment, ces fonctionnalités, dans de nombreux cas, font de GEE un choix privilégié par rapport aux postes de travail traditionnels, qui sont dans la plupart des temps équipés de logiciels et de matériel coûteux. Même si GEE

présente des avantages, il n'en demeure pas moins qu'il peut présenter divers inconvénients par rapport à d'autres environnements en raison de son cadre de programmation relativement restreint. À ce niveau, [38] précise que la version gratuite de GEE ne peut pas être utilisée à des fins commerciales. Ce qui reste toutefois une contrainte pour les grands stockages et les traitements Deep Learning comme l'a observé [1]. Aujourd'hui l'accès aux données de haute résolution spatiale dans GEE, notamment celles de Planet Scope offre un large éventail d'application de celles-ci pour la détection et la surveillance de la dynamique d'occupation du sol. Leur disponibilité ainsi que l'imagerie sentinel-1 et 2 permet d'améliorer la cartographie des unités d'occupation du sol. À cet égard, cette étude ambitionnait utiliser la combinaison des données Planet Scope, Sentinel-1 et 2 afin de disposer d'une image de très haute résolution spatiale, temporelle et spectrale pour la reconnaissance des classes d'occupation du sol du Bassin de la Marahoué. À cet effet, plusieurs bandes et indices spectraux issues de ces images notamment, les bandes B2, B3, B4, B8, B11, B12 issus des images Sentinel-2, les bandes VH et VV issues de sentinel-1 auxquelles s'ajoute la bande ratio VV_VH, les bandes B, G, R et N issues de Planet Scope et les indices spectraux MNDWI, WRI, NDWI, IBI, NDBSI, NDBI, NDVI ont été utilisés pour parvenir à un résultat satisfaisant de classification. Seize (16) classes dont Aménagements agricoles /Autres cultures et jachères non différenciées, Anacarde, Arbor cultures /Plantations fruitières, Cacao-café, Forêt claire, Forêt dense, Forêt galerie, Formations arbustives Fourrés, Habitats humains, Hévéa, Palmeraie, Plan d'eau, Plantation de Canne à sucre, Plantations forestières et reboisement, Savane arborée, Zones marécageuses ont été identifiées dans des proportions différentes sur le bassin versant de la Marahoué à partir de ces néocanaux et indices spectraux. La qualité des résultats obtenus pourrait s'expliquer par la facilité de la discrimination des classes de la part des modèles mais aussi de l'apport significatif de ces indices. Les indices spectraux MNDWI, WRI, NDWI, IBI, NDBSI, NDBI, NDVI calculés à partir des images de télédétection sont couramment utilisés en tant que facteurs pour la surveillance des cultures, des surfaces, du développement urbain et aussi de l'identification des zones humides. Leur apport dans une étude de changement à la surface terrestre est toujours profitable pour les différents algorithmes. Des conclusions et observations significatives par les auteurs [39] corroborent ces résultats obtenus. Ces derniers ont remarqué la contribution significative des indices NDVI, NDBI et NDWI dans la cartographie des changements d'occupation du sol à partir de l'imagerie sentinel-1 et 2 en utilisant l'algorithme de la forêt aléatoire en côte d'ivoire. D'autres études similaires menées en Côte d'Ivoire en 2020 par [3] et par [40] et en 2019 par [41] sont parvenues à la même conclusion. Ces auteurs ont relevé l'apport significatif de plusieurs indices spectraux parmi lesquels MNDWI, NDBI, NDVI, NDWI dans la cartographiques des classes d'occupation du sol. Au niveau de la complémentarité des images sentinel-1 et 2 dans la cartographie des classes d'occupations du sol, elle n'est plus à démontrer. Leur usage conjointe dans une telle étude permet une bonne discrimination des unités d'occupation du sol. Les images Sentinel-1 se sont avérées utiles pour surveiller les changements de détection temporel et pour discriminer les différentes classes d'occupation du sol de la Marahoué en raison de leur résolution spatiale et temporelle très élevées. Quant aux images Sentinel-2, elles ont contribué de façon significative dans la discrimination de la culture de café, de cacao, de palmier, d'hévéa et d'anacarde. Une telle conclusion avait déjà été observé par [39].

- Performance de l'algorithme Deep Forest

La cartographie des classes d'occupation d'une région à l'aide des outils issus de l'intelligence artificielle à travers l'apprentissage automatique est une avancée significative dans les études de changement terrestre. Plusieurs études menées dans le monde montrent une contribution significative de l'apprentissage automatique à travers le Machine Learning. Même si les algorithmes du Deep Learning sont très performants que ceux du machine Learning dans une étude de classification, leur utilisation demande des notions matérielles préalables. Une machine de très puissante capacité avec un CPU élevé, un temps d'attente énorme et une mise en place des algorithmes complexes. Dans cette étude, il s'agissait d'explorer les techniques qu'offre l'apprentissage profond à travers l'algorithme Deep Forest (DF) afin de rendre compte des classes d'occupation du sol du bassin versant de la Marahoué. Les résultats obtenus ont montré une domination écrasante de l'algorithme DF sur les autres classificateurs conventionnels en termes de précision qui est de l'ordre de plus 96 % dans la reconnaissance des classes d'occupation du sol. Si ces résultats sont satisfaisants dans l'ensemble, plusieurs raisons pourraient expliquer un tel exploit. D'abord l'utilisation des algorithmes usuels Extreme Gradient Boosting (XGB), Random Forest (RF) et Extra Tree (ET) comme classificateurs arborescents aurait permis de disposer d'une architecture robuste pour une classification de qualité. Le modèle DF dont l'arborescence est XGB s'est avéré plus performant dans la reconnaissance des classes d'occupation du sol que les autres modèles y compris les classificateurs conventionnels. Des études similaires menées dans la région d'Avalon au Canada en 2020 par les auteurs [4], sont parvenues aux mêmes conclusions. En effet, ces auteurs ont utilisé la combinaison des images sentinel-1, sentinel-2 et du classificateur Deep Forest pour cartographier les zones humides avec des résultats satisfaisants du DF-XGB

- Qualité des zones de culture, de formation forestière et zones humides discriminées

Dans cette étude, la cartographie de l'occupation du sol par les modèles Deep Forest a montré une bonne délimitation des zones de cultures, de formation forestière, des bâtis et des zones humides réparties sur l'ensemble du bassin. La zone d'étude est dominée par l'aménagement agricole, les autres cultures et jachères non différenciées qui couvrent près de 726 827 hectares soit 33,90 % de la superficie totale du bassin, ensuite vient la classe anacarde qui couvrent près de 525 796 hectares, soit 24,52 % de la superficie du bassin. Les cultures pérennes notamment, le café et le cacao discriminées couvrent 119 739 hectares de l'espace, soit près de 5,58 % de la superficie totale de la zone d'étude. La culture d'hévéa et de palmier qui couvrent respectivement 10 007 et 31 760 hectares, soit 0,47 % et 1,48 % de la zone d'étude. La culture de canne à sucre et les plantations fruitières ont une couverture respective de 115 513 hectares et 3 452 hectares soit, respectivement 5,39 % et 0,16 %. Au niveau des habitats humains, ces derniers ont une couverture de 53 509 hectares, soit 2,50 % de la zone d'étude. Quant aux zones humides comprenant les plans d'eau et les zones marécageuses, elles ont une superficie sur l'ensemble du secteur d'étude respectivement 7 030 hectares et 8 388 hectares, soit 0,33 % et 0,39 %. Tous ces résultats

expliquent la prédominance des terres cultivées dans le bassin versant de la Marahoué, traduisant ainsi l'importance de cet espace dans la production agricole à l'échelle nationale. Cette prédominance des terres cultivées peut s'expliquer par le fait que l'agriculture est l'un des piliers économiques de la Côte d'Ivoire, constituant ainsi le revenu de la population qui est en majorité agricole. Les cultures Cacao-Café, hévéa, palmiers à huile et anacarde identifiées dans la zone d'étude corroborent les observations de [39]. Pour ces auteurs ces cultures sont les principales sources de revenus économiques de la Côte d'Ivoire en générale. La forte prédominance de ces cultures bien évidemment entraînera la déforestation dans plusieurs localités du pays comme l'ont observé les auteurs [39], [42], [43] et [44]. Concernant la prédominance des zones arbustives et des formations forestières au nord du bassin, comme le montre la carte d'occupation du sol, s'explique par la présence des forêts classées dont celle de Zandougou, de Sanakoro, de Kowa, de Yani situées au nord du bassin et au nord-ouest, les forêts classées de Yarani et du Bandama rouge. Quant à la classe des zones bâties qui représente à la fois les villages, les villes, des activités économiques ainsi que certains sols nus, elles sont réparties sur l'ensemble de la zone d'étude mais concentrée dans la partie sud et nord est du bassin. La classe de plans d'eau représente la rivière Marahoué et des barrages agro pastoraux ont été discriminées lesquelles sont situées dans la région sud. En 2013, des conclusions et observations similaires ont été signifiés par les auteurs [45] dans l'évaluation des classes d'occupation du sol du bassin versant du Haut Bandama de l'année 1986 et 2000 à l'aide de la classification supervisée par l'algorithme du maximum de vraisemblance. Ces auteurs ont identifié les classes Eau, Habitats, Sol nus ou dégradé, Cultures, Cultures irriguées, savane arborée et Forêts réparties sur l'ensemble de leur bassin en 1986 comme en 2000. La classe cultures a été la plus dominante de toutes ces classes avec une proportion de 29,75% de la surface totale. Ces auteurs ont aussi relevé une tendance d'augmentation des cultures et des sols nus ou dégradés aux dépens des forêts et des savanes. La dégradation des forêts denses dans la zone d'étude pourrait être due aux activités anthropiques que sont les feux de brousses, l'exploitation abusive du bois, la création des plantations de café et de cacao. Ces informations sont corroborées par les auteurs [39] qui ont révélé une régression des surfaces de forêts denses et une forte activité économique.

7 CONCLUSION

La présente étude a permis d'explorer le potentiel de la combinaison d'images multi-capteurs et de l'intelligence artificielle, notamment à travers l'algorithme Deep Forest, pour la cartographie de l'occupation et de la couverture des sols dans le bassin versant de la Marahoué, en Côte d'Ivoire. Dans un contexte marqué par une forte pression anthropique, une urbanisation non planifiée et des risques naturels croissants, cette approche intégrée s'est révélée particulièrement pertinente pour améliorer la précision des classifications à haute résolution. La fusion d'images issues des capteurs Sentinel-1, Sentinel-2 et Planet Scope, enrichie par un ensemble d'indices spectraux et de néo-bandes, a permis d'optimiser la discrimination des différentes classes d'occupation du sol. L'algorithme Deep Forest, notamment dans sa version DF-XGB, a surpassé les classificateurs conventionnels en termes de précision globale, atteignant des niveaux de performance très élevés (>96 %), tout en maintenant une capacité remarquable à différencier des classes complexes telles que les zones humides, les plantations pérennes ou les forêts galeries. Par ailleurs, l'utilisation de la plateforme Google Earth Engine (GEE) s'est révélée déterminante, en facilitant l'accès aux données, la prévisualisation et le traitement parallèle à grande échelle. L'étude confirme également la complémentarité essentielle des capteurs radar et optiques dans les zones tropicales où les contraintes climatiques et environnementales limitent la qualité des données d'observation. Sur le plan spatial, les résultats ont mis en évidence la prédominance des terres agricoles, notamment les cultures d'anacarde, de cacao, d'hévéa et de palmier à huile, confirmant ainsi l'importance économique et agricole de la région. La dynamique observée des forêts, des zones humides et des espaces bâtis souligne à la fois la diversité des écosystèmes et la pression croissante exercée par les activités humaines. Cette approche offre ainsi un outil puissant pour le suivi environnemental, la gestion durable de la localité et la prévention des risques d'inondations dans le bassin versant de la Marahoué.

REFERENCES

- [1] Vizzari, M. (2022). PlanetScope, Sentinel-2, and Sentinel-1 Data Integration for Object-Based Land Cover Classification in Google Earth Engine. *Remote Sensing*, 14 (11), Article 11. <https://doi.org/10.3390/rs14112628>.
- [2] De Luca, G., M. N. Silva, João, Di Fazio, Salvatore, & Modica, G. (2022). Integrated use of Sentinel-1 and Sentinel-2 data and open-source machine learning algorithms for land cover mapping in a Mediterranean region. *European Journal of Remote Sensing*, 55 (1), 52-70. <https://doi.org/10.1080/22797254.2021.2018667>.
- [3] Njeugeut, M. A. C. N., Ta, M. Y., Satti, J.-R. K., Assoma, T. V., & Jourda, J. P. (2023). Cartographie Automatique des Zones Inondées et Evaluation des Dommages dans le District d'Abidjan depuis Google Earth Engine. *European Scientific Journal, ESJ*, 19 (32), Article 32. <https://doi.org/10.19044/esj.2023.v19n32p54>.
- [4] Jamali, A., Mahdianpari, M., Brisco, B., Granger, J., Mohammadimanesh, F., & Salehi, B. (2021). Deep Forest classifier for wetland mapping using the combination of Sentinel-1 and Sentinel-2 data. *GIScience & Remote Sensing*, 58 (7), 1072-1089. <https://doi.org/10.1080/15481603.2021.1965399>.
- [5] Assoko, A. V. S. (2022). Conception d'outils de prévision des extrêmes hydrologiques en région tropicale ouest africaine: cas du bassin versant de la Marahoué en Côte d'Ivoire. Thèse de doctorat, Institut National Polytechnique Félix HOUPOUËT BOIGNY de Yamoussoukro, 240p.

- [6] Tagini, B. (1971). Esquisse structurale de la Côte d'Ivoire. Essai de géotectonique régionale. SODEMI Abidjan.
- [7] Kouamé, K. A., Koudou, A., Sorokoby, V. M., Kouamé, K. F., & Kouassi, A. M. (2017). Relation entre les écoulements de surface et souterrain dans le bassin versant du haut Bandama en Côte d'Ivoire. *LARHYSS Journal*, 29, 137-152.
- [8] Soro, G., Noufé, D., & Goula, B. (2018). Analyse de la sensibilité d'un modèle hydrologique global aux estimations de la pluie moyenne et de l'évapotranspiration potentielle: application au bassin versant de la Marahoué en Côte d'Ivoire. *Larhyss Journal*, 33, 155-168.
- [9] Peltre Wurtz, J., & Steck, B. (1979). Influence d'une société de développement sur le milieu paysan. Coton et culture attelée dans la région de la Bagoué (Nord Côte d'Ivoire). ORSTOM.
- [10] Dje Bi, D. D. (2015). Évaluation et Planification des ressources en eau du Bassin versant de la Marahoué (centre ouest de la Côte d'Ivoire). Mémoire, Université Nangui Abrogoua, 83p.
- [11] Adon, G. C. R. (2015). Évaluation des potentialités en eau de l'hydrosystème de la haute Marahoué (Côte d'Ivoire). Thèse, Université Félix Houphouët Boigny, 177p.
- [12] Denis, G. (2016). L'exploitation Artisanale De L'or En Côte D'ivoire : La Persistance D'une Activite Illegale. *European Scientific Journal*, ESJ, 12 (3), 18. <https://doi.org/10.19044/esj.2016.v12n3p18>.
- [13] Kouadio, A. C., Kouassi, K., & Assi Kaudjhis, J. P. (2018). Orpaillage, disponibilité alimentaire et compétition foncière dans les zones aurifères du département de Bouaflé. *TROPICULTURA*, 36 (2), 369-379.
- [14] Matarira, D., Mutanga, O., Naidu, M., & Vizzari, M. (2023). Object-Based Informal Settlement Mapping in Google Earth Engine Using the Integration of Sentinel-1, Sentinel-2, and PlanetScope Satellite Data. *Land*, 12 (1), Article 1. <https://doi.org/10.3390/land12010099>.
- [15] Collin, A., James, D., & Feunteun, E. (2022). Towards better coastal mapping using fusion of high temporal sentinel-2 and planetscope-2 imageries : 12 bands at 3 m through neural network modelling. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLIII-B3-2022, 479-484. <https://doi.org/10.5194/isprs-archives-XLIII-B3-2022-479-2022>.
- [16] Mullissa, A., Vollrath, A., Odongo-Braun, C., Slagter, B., Balling, J., Gou, Y., Gorelick, N., & Reiche, J. (2021). Sentinel-1 SAR Backscatter Analysis Ready Data Preparation in Google Earth Engine. *Remote Sensing*, 13 (10), 1954. <https://doi.org/10.3390/rs13101954>.
- [17] Hird, J. N., DeLancey, E. R., McDermid, G. J., & Kariyeva, J. (2017). Google Earth Engine, Open Access Satellite Data, and Machine Learning in Support of Large Area Probabilistic Wetland Mapping. *Remote Sensing*, 9 (12), <https://doi.org/10.3390/rs9121315>.
- [18] Demissie, B., Vanhuyse, S., Grippa, T., Flasse, C., & Wolff, E. (2023). Using Sentinel-1 and Google Earth Engine cloud computing for detecting historical flood hazards in tropical urban regions : A case of Dar es Salaam. *Geomatics, Natural Hazards and Risk*, 14 (1), 2202296. <https://doi.org/10.1080/19475705.2023.2202296>.
- [19] Lopes M., Frison P., Durant S. M., Schulte to Bühne H., Ipavec A., Lapeyre V., et Pettorelli N. (2020). Combining optical and radar satellite image time series to map natural vegetation: savannas as an example. *Remote Sensing in Ecology and Conservation*, 6 (3), 316– 326.
- [20] Nguyen, H. T. T., Doan, T. M., Tomppo, E., & McRoberts, R. E. (2020). Land Use/Land Cover Mapping Using Multitemporal Sentinel 2 Imagery and Four Classification Methods—A Case Study from Dak Nong, Vietnam. *Remote Sensing*, 12, 1367.
- [21] Acharki, S., Amharref, M., Frison, P.-L., & Bernoussi, A. S. (2020). Cartographie des cultures dans le périmètre du Loukkos (Maroc): Apport de la télédétection radar et optique. *Revue Française de Photogrammétrie et Télédétection*, (222), 15-29.
- [22] Kafy, A., Khan, M. H. H., Islam, A., & Sarker, H. S. (2020). Prediction of Future Land Surface Temperature and its Impact on Climate Change: A Remote Sensing Based Approach in Chattogram City. 1st International Student Research Conference, Dhaka.
- [23] Deoli V., Kumar D., Kuriqi A. (2022). Detection of Water Spread Area Changes in Eutrophic Lake Using Landsat Data. *Sensors* 2022, 22, 6827. <https://doi.org/10.3390/s22186827>.
- [24] Liu Y., Meng Q., Zhang L., Wu C. (2022). NDBSI: A normalized difference bare soil index for remote sensing to improve bare soil mapping accuracy in urban and rural areas, *CATENA*, Volume 214, 106265, ISSN 0341-8162, <https://doi.org/10.1016/j.catena.2022.106265>.
- [25] Breiman, L. (2001). Random Forests. *Machine Learning*, 45 (1), 5-32.
- [26] Chen, T., & Guestrin, C. (2016). XGBoost : A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794. <https://doi.org/10.1145/2939672.2939785>.
- [27] Friedman, J. H. (2001). Greedy Function Approximation: A Gradient Boosting Machine. *The Annals of Statistics*, 29 (5), 1189-1232.
- [28] Breiman, L. (1996). Bagging Predictors. *Machine Learning*, 24 (2), 123-140.
- [29] Geurts, P., Ernst, D., & Wehenkel, L. (2006). Extremely randomized trees. *Machine Learning*, 63 (1), 3-42. <https://doi.org/10.1007/s10994-006-6226-1>.
- [30] Hussain, M., Bird, J. J., & Faria, D. R. (2019). A Study on CNN Transfer Learning for Image Classification. In A. Lotfi, H. Bouchachia, A. Gegov, C. Langensiepen, & M. McGinnity (Éds.), *Advances in Computational Intelligence Systems* (Vol. 840, p. 191-202). Springer International Publishing. https://doi.org/10.1007/978-3-319-97982-3_16.
- [31] Zhang, W., Tang, P., & Zhao, L. (2019). Remote Sensing Image Scene Classification Using CNN-CapsNet. *Remote Sensing*, 11 (5), Article 5. <https://doi.org/10.3390/rs11050494>.
- [32] Breiman, L., Friedman, J., Stone, C. J., & Olshen, R. A. (1984). *Classification and Regression Trees*.

- [33] Mahdianpari, M., Salehi, B., Rezaee, M., Mohammadimanesh, F., & Zhang, Y. (2018). Very Deep Convolutional Neural Networks for Complex Land Cover Mapping Using Multispectral Remote Sensing Imagery. *Remote Sensing*, 10 (7), 1119. <https://doi.org/10.3390/rs10071119>.
- [34] Cherif, E., Hell, M., & Brandmeier, M. (2022). DeepForest : Novel Deep Learning Models for Land Use and Land Cover Classification Using Multi-Temporal and -Modal Sentinel Data of the Amazon Basin. *Remote Sensing*, 14 (19), Article 19. <https://doi.org/10.3390/rs14195000>.
- [35] Nadkarni, S. B., Vijay, G. S., & Kamath, R. C. (2023). Comparative Study of Random Forest and Gradient Boosting Algorithms to Predict Airfoil Self-Noise. *Engineering Proceedings*, 59 (1), Article 1. <https://doi.org/10.3390/engproc2023059024>.
- [36] Tassi, A., Gigante, D., Modica, G., Di Martino, L., & Vizzari, M. (2021). Pixel- vs. Object-Based Landsat 8 Data Classification in Google Earth Engine Using Random Forest : The Case Study of Maiella National Park. *Remote Sensing*, 13 (12), 2299. <https://doi.org/10.3390/rs13122299>.
- [37] Michira, M. K., Rimiru, R. M., & Mwangi, W. R. (2023). Improved Multilayer Perceptron Neural Networks Weights and Biases Based on The Grasshopper Optimization Algorithm to Predict Student Performance on Ambient Learning.
- [38] Maas, M. D. (2022). 5 Things to Consider about Google Earth Engine. <https://www.matecdev.com/posts/disadvantages-earth-engine.html> (Consulté le 15 Avril 2023).
- [39] Kouassi, C. J. A., Qian, C., Khan, D., Achille, L. S., Kebin, Z., Omifolaji, J. K., Ya, T., & Yang, X. (2024). Land use land cover change mapping from sentinel 1b < 2a imagery using random forest algorithm in côte d'ivoire. *Geodesy and Cartography*, 50 (1), 43-59. <https://doi.org/10.3846/gac.2024.18724>.
- [40] N'da, H., Kaudjhis, C., & Dahan, K. S. (2021). Dynamique spatio temporelle des feux de 2001 à 2019 et dégradation du couvert végétal en zone de contact forêt savane, Département de Toumodi, Centre de la Côte d'Ivoire. *Afrique Science*, 19, 94-113.
- [41] Aka, K., N., H., Koffi, J., & Bohoussou, N. (2022). Étude comparative de Sentinel 2 et Landsat 8 OLI à l'évaluation de l'occupation du sol du site Ramsar d'Azagny, Sud de la Côte d'Ivoire. Vol. 20, N°5, 48-63.
- [42] Kouassi, C. J. A., Khan, D., Achille, L. S., Omifolaji, J. K., Espoire, M. M. R. B., Zhang, K. B., Yang, X. H., & Horning, N. (2021). Conflict-induced deforestation detection in African Côte D'ivoire using landsat images and random forest algo-rithm: A case in Mount Peko National Park. *Applied Ecology and Environmental Research*, 20 (3), 2035–2058. https://doi.org/10.15666/aeer/2003_20352058.
- [43] Assalé, A. A., Barima, Y. S., Sangne, Y. C., Bleu, D. K., & Kpan-gui, K. B. (2020). Évaluation des services d'approvisionnement fournis par les espaces domaniaux anthropisés: cas de la forêt classée du Haut-Sassandra (Centre-Ouest de la Côte d'Ivoire). *Canadian Journal of Forest Research*, 50 (10), 1002–1011. <https://doi.org/10.1139/cjfr-2019-0443>.
- [44] Ruf, F., Salvan, M., Kouamé, J., & Duplan, T. (2020). Qui sont les planteurs de cacao de Côte d'Ivoire? *Papiers de recherche* (pp. 1–111). Éditions AFD. <https://doi.org/10.3917/afd.thier.2020.01.0001>.
- [45] Soro, T. D., Kouakou, B. D., Kouassi, E. A., Soro, G., Kouassi, A. M., Kouadio, K. E., Yéi, M.-S. O., & Soro, N. (2013). Hydroclimatologie et dynamique de l'occupation du sol du bassin versant du Haut Bandama à Tortiya (Nord de la Côte d'Ivoire). *VertigO - la revue électronique en sciences de l'environnement*, Volume 13 Numéro 3, <https://doi.org/10.4000/vertigo.14468>.