



ISSN : 2958-5805 (E)
2958-5813 (P)



N° 7 / Juil - 2026

Cahier De La Recherche Africaine

Revue pluridisciplinaire : Lettres, Arts et Sciences Humaines



Problématiques africaines : Compétitivité et société

Revue indexée : Scientific Journal Impact Factor (SJIF)



CAHIER DE LA RECHERCHE AFRICAINE

**Revue Pluridisciplinaire
Lettres, Arts et Sciences Humaines**

Université Omar Bongo

Année 4 / Numéro 7 / Juillet 2026

ISSN : 2958-5805 (E)

2958-5813 (P)

PROBLÉMATIQUES AFRICAINES : COMPÉTITIVITÉ ET SOCIÉTÉ



TOGETHER WE REACH THE GOAL

Revue indexée

Scientific Journal Impact Factor (SJIF)

<https://sjifactor.com/passport.php?id=23299>

Impact Factor : 5,338



MENTION LEGALE

La rédaction du *CRA* rappelle que les opinions exprimées dans les articles ou reproduites dans les analyses n'engagent que leurs auteur(e)s.

© CNM Éditions Gabon 2026

cnmeditions.gab@gmail.com

ISSN : 2958-5805 (E) / 2958-5813 (P)

ISBN : 978-2-494270-20-6

Tous droits réservés pour tous les pays.

Toute modification interdite



Fortis Fortuna Adiuvat



Revue pluridisciplinaire : Lettres, Arts et Sciences Humaines

ISSN : 2958-5805 (E) / 2958-5813 (P)

Contacts



revue.cra@revue-cra.com

site : www.revue-cra.com

Bp. 17004, Université Omar Bongo, Libreville – Gabon

DIRECTEUR DE PUBLICATION

NDOMBI-SOW Gaël, Maître de Conférences, Université Omar Bongo

REDACTEUR EN CHEF

MAGNIMA-KAKASSA Arsène, Maître de Conférences, Université Omar Bongo

SECRETARIAT

KOMBILA YEBE MAKOUNDOU Jean Mariole, Université Omar Bongo

KOUMBA ALIHONOU Gwladys, Ecole Normale Supérieure de Libreville

MESSA Guy Christian, Université Omar Bongo

MILEBOU NDJAVE Kelly Marlène, Université Omar Bongo

MOUVONDO Epiphane, Université Omar Bongo

NGAMILOLO Loïc-Rodney, Université de Lorraine

TRESORIERE

MBANG MOULENGUI Stancia Maeva

COMITE SCIENTIFIQUE

- **DIENE Babou**, Professeur Titulaire (Littérature), Université Gaston Berger – Sénégal
- **FOTSING MANGOUA Robert**, Professeur Titulaire (Littérature), Université de Dschang – Cameroun
- **IDIATA Franck Daniel**, Professeur Titulaire (Linguistique), Université Omar Bongo – Gabon
- **LAMAH Daniel**, Professeur Titulaire (Géographie), Université de Kindia – Guinée
- **MADEBE Georice Berthin**, Directeur de Recherche (Sémiotique), Institut de Recherches en Sciences Humaines (IRSH) de Libreville – Gabon
- **MAMADOU DINDE Diallo**, Professeur Titulaire (Histoire), Université de Kankan – Guinée
- **MBONDOBARI Sylvere**, Professeur des Universités (Littérature), Université Bordeaux Montaigne – France
- **MENGUE M'OYE Alexis**, Professeur Titulaire (Histoire), Université Omar Bongo – Gabon
- **MONGUI Pierre-Claver**, Professeur Titulaire (Littérature), Université Omar Bongo – Gabon
- **N'GORAN David**, Professeur Titulaire (Littérature), Université Félix Houphouët-Boigny – Côte d'Ivoire
- **NZINZI Pierre**, Professeur Titulaire (Philosophie), Université Omar Bongo – Gabon



- **RENOMBO Steeve**, Professeur Titulaire (Littérature), Université Omar Bongo – Gabon
- **TONDA Joseph**, Professeur Titulaire (Sociologie/Anthropologie), Université Omar Bongo – Gabon
- **AKOMO ZOGHE S. Cyriaque**, Maître de Conférences (Civilisations hispano-africaines), Ecole Normale Supérieure de Libreville – Gabon
- **BIKOMA Florence**, Maître de Conférences (Anthropologie), Université Omar Bongo – Gabon
- **BISSIELO Gaël Samson**, Maître de Conférences (Linguistique appliquée), Université Omar Bongo – Gabon
- **KONAN Richmond Alain**, Maître de Conférences (Littérature), Université Félix Houphouët-Boigny – Côte d'Ivoire
- **MAGNIMA-KAKASSA Arsène**, Maître de Conférences (Littérature), Université Omar Bongo – Gabon
- **MAKITA-IKOUAYA Euloge**, Maître de Conférences (Géographie), Université Omar Bongo – Gabon
- **MAPANGOU Dacharly**, Maître de Conférences (Littérature), Université Omar Bongo – Gabon
- **MBOYI BONGO Serge**, Maître de Conférences (Histoire), Université Omar Bongo – Gabon
- **MEBIAME ZOMO Maixant**, Maître de Conférences (Anthropologie), Université Omar Bongo – Gabon
- **MOUNGUENGUI Faustin**, Maître de Conférences (Psychologie), Université Omar Bongo – Gabon
- **MOUSSOUNDA IBOUANGA Firmin**, Maître de Conférences (Linguistique), Université Omar Bongo – Gabon
- **MVE EBANG Bruno**, Université Omar Bongo, Maître de Conférences (Science Politique), Université Omar Bongo – Gabon
- **NDOMBI-SOW Gaël**, Maître de Conférences (Littérature), Université Omar Bongo – Gabon
- **OBIANG NNANG Noël Christian-Bernard**, Maître de Conférences (Histoire), Université Omar Bongo – Gabon
- **OVONO EBE Mathurin**, Maître de Conférences (Littérature espagnole), Université Omar Bongo – Gabon
- **PAMBO PAMBO N'DIAYE Anges Gaël**, Maître de Conférences (Littérature anglaise), Université Omar Bongo – Gabon
- **SANDOUONO FAYA Moïse**, Maître de Conférences (Histoire), Université de Kindia – Guinée
- **SOUMAHO MAVIOGA Orphée Martial**, Maître de Conférences (Sociologie), Université Omar Bongo – Gabon



SOMMAIRE

EFFETS LITTÉRAIRES ET COMMUNICATIONNELS 9

NDONG NDONG Yannick Martial (Université Omar Bongo – Gabon)« Promenades frontalières », un paradigme de la *weltliteratur* ?

Lire les dialogues d'écrivains ou d'artistes dans

L'énigme du retour de Dany Laferrière 11**LUÉ Jonathan** (Université Félix Houphouët Boigny – Côte d'Ivoire)

Kemitisme et rastafarisme : de la reconstruction à la déconstruction

identitaire dans *Tels des astres éteints* de Leonora Miano 31**MOUNZIEGOU-MOMBO Narcice Wolgan** (Université Omar Bongo – Gabon)**MOUTANGOU Fabrice Anicet** (Université Omar Bongo – Gabon)

Les élites intellectuelles gabonaises et l'affirmation

d'une audience historico-politique : approche à

partir des mémoires et des récits de vie 45

CAMARA Aya Anita (Université Alassane Ouattara – Côte d'Ivoire)**KONAN Koffi Syntor** (Université Alassane Ouattara – Côte d'Ivoire)

De las minorías sexuales en el inmediato posfranquismo :

análisis de *El mismo mar de todos los veranos* de Esther Tusquets 61

HUMANITÉS CLASSIQUES ET PERSPECTIVES MODERNES

EN SCIENCES SOCIALES 73

NGUIABAMA-MAKAYA Fabrice (Université Omar Bongo – Gabon)

Les migrations forcées et encadrées de la politique coloniale française

au Gabon (1887-1946) 75

MEITE Ben Soualiouo (Université Félix Houphouët-Boigny – Côte d'Ivoire)**YEO Mamadou** (Université de San Pedro – Côte d'Ivoire)

Marie Diongoye Konate, trajectoire d'une entrepreneure migrante

au cœur de l'intégration ivoiro-malienne (1984-2002) 91

OMBIGATH Pierre Romuald (Université Omar Bongo – Gabon)

Héritages coloniaux et recompositions postindépendance :

les télécommunications au Gabon entre logiques administratives

et contraintes structurelles (1930–1990) 111

MOUDJOURI Bienvenue Merci (Université de Garoua – Cameroun)

La francophonie dans la construction de la stabilité constitutionnelle

en Afrique Centrale 127



NSANGOU Amadou (Université de Maroua – Cameroun) MOUNTAPMBEME Jean Paul (Université de Dschang – Cameroun) L’art de bronze dans le royaume Bamun (1917-1960) : patrimoine, symbole politique et enjeux touristiques	139
SORO Sotianhoua (Université Peleforo Gon Coulibaly – Côte d’Ivoire) COULIBALY Yalamoussa (Université Alassane Ouattara – Côte d’Ivoire) Le poro privé des Senoufo de Côte d’Ivoire et son importance : cas du waw des Nafanra et du Noncara des Fodonnnon	149
BIVEGHE BI NDONG Wilfried (Institut de Recherche en Sciences Humaines – Gabon) Genre et pouvoir dans l’entreprise gabonaise : vers de nouvelles formes de leadership féminin ?	165
MEITE Méfégbé (Université Alassane Ouattara – Côte d’Ivoire) Entre efficacité et illusion, les pratiques divinatoires en Afrique : une béquille morale	179
SEKONGO Nonhoua Thomas (Université Alassane Ouattara – Côte d’Ivoire) Regard croisé sur la pratique médicale à l’ère de l’intelligence artificielle : enjeux et limites	191
MASSALA MBINDZOUKOU Marius (Université Omar Bongo – Gabon) MOUKETOU TARAZEWICZ Dieudonné (Université Omar Bongo – Gabon) OBIANG OBIANG Luckin (Université Omar Bongo – Gabon) Évaluation des performances des algorithmes du réseau des neurones convulsifs (RNC), des machines à vecteur de support (SVM), et du maximum de vraisemblance (MV) pour la cartographie des plantations agricoles	205



HUMANITÉS CLASSIQUES ET PERSPECTIVES MODERNES EN SCIENCES SOCIALES

ÉVALUATION DES PERFORMANCES DES ALGORITHMES DU RÉSEAU DES NEURONES CONVULSIFS (RNC), DES MACHINES À VECTEUR DE SUPPORT (SVM), ET DU MAXIMUM DE VRAISEMBLANCE (MV) POUR LA CARTOGRAPHIE DES PLANTATIONS AGRICOLES

Marius MASSALA MBINDZOUKOU

Université Omar Bongo

mariusmassala@gmail.com

&

Dieudonné MOUKETOU TARAZEWICZ

Université Omar Bongo

dieudonne@expetrop.com

&

Luckin OBIANG OBIANG

Université Omar Bongo

obiangobiang8@gmail.com

Résumé : Le Gabon s'engage depuis plusieurs années dans la diversification de son économie, plaçant l'agriculture au cœur de sa stratégie. Cependant, la cartographie des plantations et des types de cultures est freinée par le morcellement parcellaire et la complexité des paysages tropicaux. Cette étude explore l'application des algorithmes pour la classification des plantations agricoles et des cultures dans la zone de Lémbamba à partir des algorithmes du Réseau de Neurones Convolutifs (RNC), de Machines à Vecteurs de Support (SVM) et du Maximum de Vraisemblance (MV). L'approche méthodologique repose sur une classification hiérarchique exploitant l'imagerie satellitaire Sentinel-2, les relevés GPS et la très haute résolution spatiale des images drone. Les résultats démontrent que pour l'identification des plantations agricoles, la combinaison Drone-RNC (Réseau de Neurones Convolutifs) surpasse les approches utilisées. Elle réduit significativement les erreurs de commission et d'omission, atteignant des précisions globales comprises entre 96,34 % et 98,73 % (indices Kappa entre 0,93 et 0,97). Concernant la discrimination des cultures de banane et de manioc, l'apport du drone est décisif car il a permis de franchir un verrou technique en faisant passer l'indice Kappa de 0,00 à 0,63. L'étude conclut que la précision géométrique des Régions d'Intérêt (ROI) issues du drone, couplée à la puissance de modélisation du RNC, constitue une solution optimale pour cartographier les systèmes agricoles complexes.

Mots-clés : Sentinel-2 ; Drone ; RNC ; Plantations agricoles ; Cultures ; Gabon ; Lémbamba

Abstract : For several years, Gabon has been committed to diversifying its economy, placing agriculture as a key sector. However, mapping agricultural plantations and crop types is hindered by land fragmentation and the complexity of tropical landscapes. To support decision-makers, integrating innovative scientific methods into crop monitoring is essential. The general objective of this study is to develop and evaluate a methodology for identifying agricultural plantations and crops in the Lémbamba area. The methodological approach is based on a hierarchical classification integrating the complementarity between Sentinel-2 satellite imagery, GPS surveys, and the very



high spatial resolution of drone imagery. The results demonstrate that for agricultural plantation identification, the Drone-CNN (Convolutional Neural Network) combination outperforms all other approaches. It significantly reduces commission and omission errors, achieving overall accuracies ranging between 96.34% and 98.73% (Kappa indices between 0.93 and 0.97). Regarding the discrimination of crop types (banana vs. cassava), the drone's contribution is decisive: it overcame a technical bottleneck by increasing the Kappa index from 0.00 (total failure with GPS alone) to 0.63. The study concludes that the geometric precision of drone-derived Regions of Interest (ROI), coupled with the power of CNN non-linear modeling, provides an optimal solution for mapping agricultural systems in this region.

Keywords : Sentinel-2 ; Drone ; CNN ; Agricultural plantations ; Crops ; Gabon ; Lébamba

Introduction

La cartographie des zones agricoles et des cultures agricoles constitue un enjeu majeur pour la gestion durable des ressources, la sécurité alimentaire et la planification territoriale (Foerster et *al.*, 2012 : 30 ; Pelletier et *al.*, 2017: 1; Blickensdörfer et *al.*, 2022 : 1). Ce besoin est accentué par un contexte mondial marqué par la croissance démographique et les changements climatiques qui menacent durablement la production mondiale (Sultan et *al.*, 2015 : 430 ; Savary et *al.*, 2019 : 209-210). En Afrique, où se concentrent d'importantes pertes de surfaces arables (Bren d'Amour et *al.*, 2017, p. : 8940-8941), la connaissance fine de la répartition des cultures devient un levier stratégique pour orienter les politiques de développement rural. Face à cette vulnérabilité, le recours à l'imagerie satellitaire semble à nos yeux comme une piste de solution stratégique. Les progrès récents de la télédétection spatiale ont permis de développer de nouvelles approches pour identifier et analyser les dynamiques agricoles à différentes échelles (Defourny et *al.*, 2019 : 552; Blickensdörfer et *al.*, 2022 : 2-16; Courault et *al.*, 2024 : 1). Les capteurs multispectraux, notamment ceux de la mission Sentinel-2, offrent des données à haute résolution spatiale et temporelle permettant d'extraire des caractéristiques spectrales utiles pour les études agricoles (Tran et *al.*, 2022 : 30-31). Parallèlement, l'intégration d'algorithmes, tels que les Machines à Vecteurs de Support (SVM) et les Réseaux de Neurones Convolutifs (RNC), permet d'accroître significativement la robustesse de l'identification des couverts végétaux (Koné et *al.*, 2026 : 131-136).

Au Gabon, l'agriculture repose majoritairement sur de très petites exploitations familiales, dispersées et souvent situées dans des zones difficiles d'accès. Cette configuration rend les opérations de recensement et le suivi statistique de la production extrêmement complexes, limitant la capacité de l'État à structurer efficacement les filières. Si des travaux (Nzigou Boucka et *al.*, 2021 : 118) basés sur les approches traditionnelles de télédétection ont permis d'établir des bases d'une occupation du sol, il n'en demeure pas moins que


Évaluation des performances des algorithmes du réseau des neurones convulsifs (RNC), des machines à vecteur de support (SVM), et du maximum de vraisemblance (MV) pour la cartographie des plantations agricole

l'absence des travaux basés sur une distinction taxonomique fine entre les types de cultures au Gabon, constitue aujourd'hui un verrou majeur. Face à cette lacune, nous pensons que la télédétection couplée à l'IA est une piste potentielle. Dans le présent travail, nous avons évalué trois méthodes d'apprentissage automatique (Maximum de Vraisemblance, SVM et RNC) afin de déterminer le modèle le plus robuste pour la cartographie des plantations agricoles et types de cultures dans la commune de Lébamba (Gabon).

1. Localisation de la zone d'étude

La zone d'étude (figure 1) est située dans la province de la Ngounié au sud du Gabon, plus précisément dans le département de la Louésie-Wano. Elle s'étend sur 270,70 km² autour du pôle urbain de Lébamba et son réseau de villages périurbains. Comprise entre 2°05'24" à 2°17'23" de latitude Sud et 11°24'43" à 11°36'50" de longitude Est, cette aire est structurée par un réseau hydrographique actif, composé du fleuve Ngounié et de la rivière Louésie. Le paysage, majoritairement composé de plaines à l'ouest s'élevant progressivement vers des collines et des plateaux à l'est, présente des altitudes variantes entre 188 et 432 mètres. Le climat de type tropical caractérisé par des précipitations mensuelles oscillant entre 24 et 373 mm, des températures moyennes stables (entre 23,8 °C et 25,1 °C) et une durée d'ensoleillement atteignant jusqu'à 5,9 heures par jour entre mars et mai.


Figure 1: Localisation de la commune de Lébamba et ses environs



2. Méthodologie

La présente étude repose sur une approche méthodologique intégrée, combinant des données satellitaires et des relevés de terrain. L'objectif est d'arriver à caractériser le mieux possible les plantations agricoles et les types de cultures. La démarche (figure 2) se décompose en quatre phases majeures, à savoir la collecte, les pré-traitements, le traitement et les analyses des données.

Figure 2 : Processus d'identification des plantations agricoles et des cultures



2.1. Matériels et données utilisées

L'étude a mobilisé des images satellitaires Sentinel-2, des levés GPS et des images drone. Les images satellitaires Sentinel-2 ont été privilégiées pour leur résolution spatiale et leur politique de libre accès. Seules celles présentant une résolution spatiale de 10 m et 20 m ont été retenues pour leur pertinence dans la caractérisation de la végétation (Frampton et *al.*, 2013 : 5-6). Les bandes de 10 m (Bleu, Vert, Rouge et Proche Infrarouge) ont été exploitées pour l'analyse de la structure foliaire et de l'absorption chlorophyllienne, tandis que les bandes de 20 m (Bord rouge et Infrarouge de courte longueur d'onde) ont fourni des indicateurs sur l'état physiologique et le contenu en eau des cultures (Segarra et *al.*, 2020 : 5-6). Nous avons privilégié les données fournissant une réflectance de surface en raison de leur adéquation aux analyses scientifiques (Obregón et *al.*, 2019 : 2, 3 et 4). La recherche d'images a porté sur la période du 1er janvier 2023 au 31 décembre 2024 afin de maximiser la probabilité d'obtenir des scènes faiblement nuageuses. Après l'étape de filtrage, seules les

images acquises en avril 2024 ont présenté une qualité suffisante pour garantir la fiabilité des analyses thématiques.

2.2. Traitements

Pour aboutir à une identification exhaustive des cultures et la garantie d'une meilleure précision thématique, nous avons structuré hiérarchiquement nos classifications en 3 niveaux. La première phase a été consacrée aux prétraitements. Nous avons procédé aux calculs d'une série d'indices. L'Indice de Différence Normalisée de Bâti (NDBI) a été exploité pour isoler les surfaces imperméabilisées, tandis que l'Indice Modifié de Différence Normalisée d'Eau (MNDWI) a permis une extraction précise du réseau hydrographique. L'Indice de Sol Nu (BSI) a été déterminant pour identifier les sols nus. La deuxième a été celle des compositions colorées. Ces traitements ont été testés pour améliorer les discussions des classes végétales. La combinaison infrarouge (B8-B11-B3) a été privilégiée pour mettre en évidence la biomasse active, tandis que les couleurs naturelles (B4-B3-B2) ont facilité la lecture globale du paysage. Les combinaisons de végétation (B7-B8A-B12) et agricoles (B11-B8-B2 et B11-B8A-B2) ont été essentielles pour distinguer les plantations agricoles des autres classes végétales. Aussi, le traitement des images drones a permis de générer des orthomosaïques et des Modèles Numériques de Surface (MNS). Cette étape a été suivie d'une vectorisation manuelle des contours parcellaires sous QGIS. Enfin, les données de référence issues des levés GPS ont fait l'objet d'un filtrage strict, ne conservant que les points présentant une erreur de positionnement inférieure ou égale à 2 mètres, avant d'être intégrées sous QGIS pour une validation finale de la cohérence spatiale. Pour la classification des images satellites, l'approche par pixel a été retenue (Ghimire et al. 2010 : 45-46, Wu et al. 2023 : 3) à travers trois algorithmes. Le Maximum de Vraisemblance (MV), fondé sur le théorème de Bayes (Mihindou Mihindou 2024 : 79) et une distribution normale gaussienne (Mondal et al., 2012 : 117-118), a été choisi pour son aptitude à comparer chaque pixel aux classes définies (Linbongui 2016 : 82). Le Support Vector Machine (SVM) a été implémenté avec un noyau de fonction de base radiale (Linbongui 2016 : 83) pour séparer les classes via un hyperplan optimal (Idbraim 2009 : 19-20), permettant d'identifier des frontières complexes (Melgani et Bruzzone 2004 : 1779-1781). Enfin, les Réseaux Neuronaux Convolutifs (CNN) ont été introduits pour leur efficacité en imagerie et leur aptitude au pré-entraînement (Kaddour Drizi, 2022 : 8, 18 et 26), avec un apprentissage stabilisé par un taux de 0.2 et un momentum de 0.9



sur 1000 itérations. Les résultats des classifications ont été vérifiés et validés par une matrice de confusion (Congalton & Green, 2019) et par l'échelle d'évaluation de Landis & Koch (1977) Landis & Koch (1977), afin de quantifier avec précision la performance thématique de nos algorithmes.

Tableau 1 : Interprétation du coefficient Kappa

Valeur du coefficient Kappa (κ)	Qualité de l'accord (Fiabilité)
< 0,20	Très faible-Mauvaise
0,21 - 0,40	Faible-Médiocre
0,41 - 0,60	Modérée
0,61 - 0,80	Bonne-Forte
0,81 - 1,00	Excellente-Accord presque parfait

Source : Landis & Koch, 1977

3. Résultats

Les résultats font ressortir la discrimination spatiale des plantations agricoles et des cultures de manioc et de banane plantain. Dans un premier temps, les plantations sont identifiées au sein de l'occupation du sol globale via les modèles RNC, SVM et MV. Ensuite, l'algorithme RNC est utilisé pour isoler les surfaces agricoles au sein des seules classes végétales. Enfin, l'étude aboutit à la distinction spécifique entre le manioc et la banane.


3.1. Identification des plantations agricoles dans les classes d'occupation du sol avec données GPS

La classification initiale avec les données GPS a montré, à travers la matrice de confusion (tableaux 2), la supériorité du RNC, notamment pour la classe parcelle agricole qui constitue notre repère dans cette étude. Pour ce qui est de la précision globale, ce dernier enregistre une précision globale de 98.85 % et un coefficient Kappa de 0.97, devant le SVM (98.68 % de précision globale et 0.96 de coefficient Kappa) et le MV (97.50% de précision globale et 0.93 coefficient Kappa). Au niveau de notre classe cible, l'analyse comparative des erreurs pour la classe plantation agricole (PA) met en lumière des comportements de classification distincts. Le modèle RNC, bien que plus restrictif avec une erreur d'omission de 58,65 %, s'avère être le plus précis lors de l'identification effective d'une plantation, affichant la plus faible erreur de commission (18,10 %). À l'opposé, le modèle MV privilégie la détection exhaustive avec une précision producteur remarquable de 94,23 %, mais au prix d'une saturation cartographique extrême (commission de 73,26 %). En d'autres

Évaluation des performances des algorithmes du réseau des neurones convulsifs (RNC), des machines à vecteur de support (SVM), et du maximum de vraisemblance (MV) pour la cartographie des plantations agricole

termes, si le MV identifie presque toutes les parcelles réelles, il classe à tort une immense surface de végétation en zone agricole. Pour une cartographie de précision où l'on veut éviter les "faux positifs". Le SVM se situe entre les deux autres. Il oublie presque la moitié des plantations (46,15 % d'omission), mais il est relativement fiable quand il en trouve une (77,78 % de précision utilisateur). Il est moins "sévère" que le RNC, mais moins "exagéré" que le MV. Le modèle RNC reste donc le choix le plus fiable malgré sa tendance à sous-estimer la surface totale. Suite à la validation statistique, la distribution spatiale des classes est restituée sous forme de cartes d'occupation du sol (figure 11). Cette approche cartographique permet de spatialiser les performances des trois algorithmes. L'analyse visuelle des produits finaux confirme la supériorité du modèle RNC pour la cohérence des textures, tandis que les cartes SVM et MV révèlent des confusions localisées surtout entre bâti et sols nus, conformément aux résultats des matrices de confusion.

Figure 3 : Planche de cartographie et de discrimination des plantations agricoles par modèles RNC, SVM et MV à partir de données GPS (Niveau 1)






3.2. Identification des plantations agricoles dans les classes d'occupation du sol avec les données drone

L'identification des plantations agricoles dans les classes d'occupation du sol avec les données drones montre une meilleure performance du RNC avec une précision globale de 98.73 % et un coefficient Kappa de 0.97, suivi par le SVM avec une précision globale de 98.22 % et un Kappa de 0.95. La méthode de MV, quant à elle, atteint une précision globale de 97.25 % et un Kappa de 0.93, nettement inférieur aux deux premiers. En termes de précisions de notre classe visée, l'analyse des erreurs pour la classe PA confirme la supériorité statistique du modèle RNC, qui affiche un excellent équilibre avec une précision du producteur de 89,60 % et une erreur d'omission limitée à 10,40 %. Bien que le modèle MV présente la plus forte sensibilité de détection (92,50 %), il souffre d'une erreur de commission très élevée (33,59 %), traduisant une importante surestimation spatiale de la classe cible par confusion avec les autres classes de végétation. Le SVM s'avère plus restrictif, omettant près de 20 % des plantations réelles. En conclusion, le RNC demeure l'algorithme le plus fiable pour une cartographie rigoureuse des parcelles agricoles.

Les cartes d'occupation du sol issues des données drone (figure 12), des trois modèles authentifient visuellement les résultats statistiques. Le modèle RNC produit la cartographie la plus précise, avec une identification appropriée aux plantations agricoles et une meilleure continuité des strates végétales. En revanche, les cartes SVM et MV affichent une plus forte fragmentation spatiale, validant ainsi la supériorité du RNC pour la production cartographique finale.

Évaluation des performances des algorithmes du réseau des neurones convulsifs (RNC), des machines à vecteur de support (SVM), et du maximum de vraisemblance (MV) pour la cartographie des plantations agricole

Figure 4 : Planche de cartographie et de discrimination des plantations agricoles par modèles RNC, SVM et MV à partir de données drone (Niveau 1)




3.3. Identification des plantations agricoles dans les classes d'occupation du sol avec la combinaison des deux sources

Le modèle RNC domine avec 98,28 % de précision et un Kappa de 0,96, excellant sur la végétation dense (99,94 %) et l'eau (100 %). Le SVM suit de près avec 98,09% de précision et un Kappa de 0,95, mais peine sur les zones bâties (65,74 %) et les plantations agricoles (17,14 % d'omissions). Le modèle MV affiche la performance la plus basse (97,07 %) avec des faiblesses marquées sur le bâti (64,19 %). Il présente également un fort taux de commission de 29,93 % pour les plantations agricoles. L'analyse des erreurs pour la classe PA (tableaux 4) montre que le modèle RNC offre le meilleur compromis avec une précision du producteur de 89,56 %, limitant l'omission à environ 10 %. Si le modèle MV affiche une sensibilité de détection équivalente (89,87 %), il souffre d'une erreur de commission très élevée (29,93 %), traduisant une forte surestimation des surfaces agricoles. Le SVM, bien que plus sélectif, omet davantage de parcelles réelles (17,14 %). Ainsi, le RNC s'impose comme l'algorithme le plus équilibré pour cartographier fidèlement nos plantations agricoles. La traduction cartographique (figure 13) des résultats témoigne de la précision du modèle RNC, qui spatialise les plantations agricoles avec une netteté supérieure. Contrairement aux cartes SVM et MV, où ces plantations



apparaissent fragmentées ou confondues avec la végétation naturelle, le RNC restitue fidèlement la structure du paysage agricole. Cette supériorité visuelle valide l'usage des réseaux de neurones pour une cartographie précise de notre classe cible.

Figure 5 : Planche cartographie et discrimination des plantations agricoles par modèles RNC, SVM et MV avec données combinées (Niveau 1)




3.4. Identification des plantations agricoles dans les classes végétales avec les données GPS, drone et combinaison des deux sources combinées au RNC

L'évaluation de la qualité des classifications effectuée montre, à travers la matrice de confusion (tableaux 5), que malgré les précisions globales excellentes (entre 95,16 % et 97,11 %), avec un indice Kappa stable à 0,93, l'analyse détaillée de notre classe cible, plantations agricoles (PA), révèle des disparités fondamentales. Le modèle basé sur les données GPS seules s'avère le moins performant pour cette classe, affichant une erreur d'omission critique de 27,07 %. Ce résultat indique qu'un échantillonnage uniquement terrestre échoue à capturer près d'un tiers de la réalité agricole. À l'inverse, les données Drone démontrent une forte sensibilité de détection avec une erreur d'omission réduite à 8,78 %, confirmant l'apport de la très haute résolution spatiale pour identifier les parcelles. Cependant, la Matrice de Combinaison (GPS + Drone) s'impose comme la solution la plus robuste pour la production cartographique. Elle enregistre la meilleure précision Utilisateur (92,93 %), limitant l'erreur de

commission à seulement 7,07 %. Cette synergie de données permet d'épurer la classification en réduisant drastiquement les fausses détections souvent confondues avec la végétation naturelle.

La spatialisation des résultats (figure 14) assure les performances statistiques observées. La carte issue de la fusion GPS + drone offre la représentation la plus précise, avec une bonne identification des plantations agricoles et une meilleure continuité des strates végétales. Comparativement aux cartes GPS ou drone prises isolément, cette approche hybride réduit le bruit cartographique et restitue fidèlement la complexité du paysage, validant ainsi la supériorité de la combinaison des données pour la cartographie finale.

Figure 6 : Planche cartographie et discrimination des plantations agricoles par le RNC et les différentes sources de données dans les classes végétales



3.5. Identification des types de cultures avec les données GPS, drone et combinaison des deux sources.


L'évaluation de la performance du modèle RNC et les sources des données (GPS, drone et combinaison des deux sources) pour l'identification spécifique des types de cultures (tableaux 6) affiche une exactitude globale de 87,12 %, mais un coefficient Kappa nul (0,00) pour la combinaison RNC et GPS. Cette divergence majeure entre la précision globale et le Kappa révèle un biais structurel profond dans la reconnaissance thématique. En effet, l'analyse



de la matrice de confusion montre que si le modèle identifie correctement 115 pixels de manioc, il échoue intégralement dans la détection de la culture de banane, pour laquelle aucune donnée n'est classée (0 pixel identifié sur les 17 attendus). Le modèle a systématiquement assimilé les parcelles de bananiers à celles du manioc, générant une précision de producteur nulle pour cette classe. Ces résultats critiques démontrent l'incapacité de l'algorithme, sous cette configuration de données GPS, à discriminer des cultures aux signatures spectrales ou aux structures trop proches. Les résultats obtenus grâce aux délimitations des plantations de ces deux cultures par l'imagerie drone permettent d'atteindre une performance globale plus nuancée mais scientifiquement plus robuste, avec une exactitude de 81,64 % et un coefficient Kappa de 0,63, traduisant un accord substantiel. La classe banane affiche une précision de production de 90,87 % (478 pixels sur 526). On note toutefois une sur-classification de la banane, avec une précision d'utilisation de 74,11 % et un taux de commission de 25,89 %, due à l'inclusion de 167 pixels de manioc dans cette catégorie. Parallèlement, le manioc présente une précision de production de 74,11 % mais une excellente précision d'utilisation (90,87 %).

La combinaison des deux sources pour l'identification des types de cultures montre une précision globale de 76,86 % et un coefficient Kappa de 0.53, indiquant une performance modérée. La classe manioc obtient 82,97 % en précision du producteur et 77,90 % en précision d'utilisateur. Pour la classe banane, ces valeurs sont respectivement de 68,74 % et 75,24 %. Les erreurs d'omission et de commission varient entre 17 % et 31 %. Ce qui démontre que le modèle reste fiable malgré une confusion entre classes. La visualisation spatiale (figure 15) confirme la hiérarchie établie par les matrices. La carte GPS illustre l'échec du modèle (Kappa 0,00) par une saturation totale du manioc. À l'inverse, le modèle Drone se traduisant visuellement par une discrimination entre les bananiers (jaune) et le manioc (vert). La combinaison des points GPS et image Drone propose une vision intermédiaire ; elle reste en retrait par rapport à la précision du Drone seul.

Figure 7 : planche cartographique comparative de la distribution spatiale des cultures de bananiers et de manioc selon la source de données d'apprentissage (Niveau 3)



4. Discussion

Le protocole hiérarchique en trois niveaux adoptés ici permet de lever les verrous liés aux nomenclatures trop génériques souvent rencontrées au Gabon (Nzigou Boucka et *al.*, 2021 : 125). L'originalité majeure de ce travail réside dans la substitution des points GPS traditionnels par des Régions d'Intérêt (ROI) issues d'une orthomosaïque drone. Cette approche fournit des échantillons plus denses et spatialement cohérents. Comme le soulignent Gómez et *al.*, (2016 : 63), la robustesse d'une classification dépend de la pureté spectrale des échantillons. La supériorité du Réseau de Neurones Convulsifs (RNC) sur le Maximum de Vraisemblance et le SVM s'explique par sa capacité à modéliser des relations non linéaires complexes. Ces observations corroborent les travaux de Mustapha et *al.*, (2010 : 2852-2853), montrant que les algorithmes neuronaux surpassent les modèles paramétriques lorsque les signatures spectrales sont hétérogènes. À l'inverse, l'instabilité du SVM face aux chevauchements spectraux rejoint les limites rapportées par (Immitzer et *al.*, 2016 : 10-11). L'analyse des classes végétales s'avère plus complexe et montre une légère baisse des performances. Au niveau 2, la précision atteint 97,11 % avec le GPS, 96,34 % avec les données drones et chute à 95,16 % lors de la combinaison des sources. Le coefficient Kappa reste néanmoins stable autour



de 0,93. Nonobstant, l'échantillonnage uniquement terrestre (GPS) affiche une erreur d'omission critique de 27,07 %, échouant à capturer près d'un tiers de la réalité agricole. À l'inverse, l'apport de la très haute résolution drone réduit cette omission à 8,78 %, confirmant une sensibilité de détection nettement supérieure pour identifier les parcelles. Au niveau 3 (Types de cultures) : L'échec du GPS seul est patent (Kappa de 0,00), incapable de distinguer la banane du manioc. L'imagerie drone rectifie ce biais (Kappa de 0,63), bien que la fusion brute (GPS+Drone) montre ici une performance modérée (Kappa de 0,53). Cette baisse de performance souligne l'exacerbation des confusions spectrales entre plantations et végétation naturelle. En phase végétative, la convergence des signatures réduit la séparabilité statistique (Lambert et *al.*, 2018 : 648). La classification des cultures reste complexe à cause de cycles phénologiques proches (Ozdogan et *al.*, 2010 : 2276, 2277 et 2281; Ibrahim et *al.*, 2021 : 1). Le passage d'un indice Kappa de 0,00 à 0,63 valide l'apport de la très haute résolution pour lever les confusions taxonomiques (Zheng et *al.*, 2024 : 1). Toutefois, l'échec de la fusion brute montre qu'une accumulation de données sans recalage millimétrique nuit à la performance. Malgré des résultats probants, plusieurs limites subsistent : Premièrement, la résolution de Sentinel-2 (10 m) est contraignante face au morcellement agricole. La petite taille des parcelles génère des pixels mixtes et complique l'extraction de signatures pures. Deuxièmement, la forte couverture nuageuse au Gabon limite la disponibilité des images. L'étude s'appuie sur une image unique d'avril 2024, ce qui empêche l'analyse temporelle. Cette absence de séries chronologiques réduit la capacité à distinguer des espèces aux cycles de croissance asynchrones. Troisièmement, la similitude spectrale entre la banane et le manioc reste un verrou en début de cycle. Leurs réponses radiométriques sont trop proches pour garantir une parfaite séparabilité. De plus, la fusion brute des données hétérogènes peut générer un bruit nuisible à la précision globale. Enfin, sur le plan opérationnel, le déploiement du drone reste coûteux et complexe. Ces contraintes logistiques limitent actuellement la répliquabilité de cette méthode à l'échelle nationale.

Conclusion

Cette étude a permis de démontrer que la cartographie précise des plantations agricoles et la distinction entre les cultures de manioc et de banane plantain à Lébamba reposent sur une synergie technologique spécifique. La comparaison des performances algorithmiques révèle la supériorité du Réseau de Neurones Artificiels (RNC), lequel s'impose comme le modèle le plus robuste pour modéliser la complexité du paysage par rapport au Maximum de

Vraisemblance et au SVM. Concernant les sources de données, l'apport de la très haute résolution spatiale des images drone constitue le levier de performance principal ; elle permet de réduire l'erreur d'omission à seulement 8,78 % et de lever le verrou taxonomique entre le manioc et la banane (Kappa de 0,63), là où l'échantillonnage GPS seul s'avère inopérant.

Malgré ces résultats, ce travail ouvre de nouvelles voies de recherche. Pour pallier la contrainte de la couverture nuageuse qui a limité cette étude à une analyse sur image unique, l'intégration de données Radar (SAR) permettrait un suivi temporel continu de la phénologie des cultures. Par ailleurs, l'amélioration des techniques de recalage géométrique pour optimiser la fusion multi-sources constitue un enjeu majeur pour accroître la précision du niveau 3. Enfin, l'adoption d'approches d'apprentissage automatique (Machine Learning) plus avancées, notamment l'utilisation d'algorithmes tels que les Forêts Aléatoires (Random Forest) ou le Gradient Boosting (XGBoost), permettrait de mieux gérer le déséquilibre des échantillons et la forte hétérogénéité spectrale observée.

Bibliographie

- BLICKENDÖRFER Lukas, SCHWIEDER Marcel et *al.*, (2022), « Mapping of crop types and crop sequences with combined time series of Sentinel-1, Sentinel-2 and Landsat 8 data for Germany », *Remote Sensing of Environment*, n°269, 112831. Disponible en ligne : <https://doi.org/10.1016/j.rse.2021.112831> [dernier accès mars 2026].
- BREN D'AMOUR Christopher, REITSMA Femke, et *al.*, (2017), « Future urban land expansion and implications for global croplands », *Proceedings of the National Academy of Sciences*, n°114(34), pp. 8939-8944. Disponible en ligne : <https://doi.org/10.1073/pnas.1606036114> [dernier accès mars 2026].
- BURKE Marshall & LOBELL David, (2017), « Satellite-based assessment of yield variation and its determinants in smallholder African systems », *Proceedings of the National Academy of Sciences*, n°114(9), pp. 2189-2194. Disponible en ligne : <https://doi.org/10.1073/pnas.1616919114> [dernier accès mars 2026].
- CONGALTON Russell & GREEN Kass, (2019), *Assessing the accuracy of remotely sensed data : Principles and practices* (3e éd.). CRC Press. <https://doi.org/10.1201/9780429052729>
- COURAULT Dominique, BELAUD Gilles, DEMAREZ Valérie, BAGHDADI Nicolas & BAILLY Jean-Stéphane, (2024), « Contribution de la télédétection pour caractériser les zones irriguées et les prélèvements d'eau pour l'irrigation », *Sciences Eaux & Territoires*, n°45, 8143. Disponible en ligne : <https://doi.org/10.20870/Revue-SET.2024.45.8143> [dernier accès mars 2026].



- DEFOURNY Pierre, BONTEMPS Sophie, BELLEMANS Nicolas et al., (2019), « Near real-time agriculture monitoring at national scale at parcel resolution : Performance assessment of the Sen2-Agri automated system in various cropping systems around the world », *Remote Sensing of Environment*, n°221, pp. 551-568. Disponible en ligne : <https://doi.org/10.1016/j.rse.2018.11.007> [dernier accès mars 2026].
- FOERSTER Saskia, KADEN Klaus, FOERSTER Michael & ITZEROTT Sibylle, (2012), « Crop type mapping using spectral–temporal profiles and phenological information », *Computers and Electronics in Agriculture*, n°89, pp. 30-40. Disponible en ligne : <https://doi.org/10.1016/j.compag.2012.07.015> [dernier accès mars 2026].
- FRAMPTON William James, DASH Jadunandan et al., (2013), « Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation », *ISPRS Journal of Photogrammetry and Remote Sensing*, n°82, pp. 83-92. Disponible en ligne : <https://doi.org/10.1016/j.isprsjprs.2013.04.007> [dernier accès mars 2026].
- GHIMIRE Bina, ROGAN John & MILLER Jennifer, (2010), « Contextual land-cover classification : Incorporating spatial dependence in land-cover classification models using random forests and the Getis statistic », *Remote Sensing Letters*, n°1(1), pp. 45-54. Disponible en ligne : <https://doi.org/10.1080/01431160903252327> [dernier accès mars 2026].
- GÓMEZ Cristina, WHITE Joanne & WULDER Michael, (2016), « Optical remotely sensed time series data for land cover classification : A review », *ISPRS Journal of Photogrammetry and Remote Sensing*, n°116, pp. 55-72. Disponible en ligne : <https://doi.org/10.1016/j.isprsjprs.2016.03.008> [dernier accès avril 2026].
- IBRAHIM Esther Shupel, RUFIN Philippe, et al., (2021), « Mapping Crop Types and Cropping Systems in Nigeria with Sentinel-2 Imagery », *Remote Sensing*, n°13(17), 3523. Disponible en ligne : <https://doi.org/10.3390/rs13173523> [dernier accès mars 2026].
- IDBRAIM Soufiane, (2009), *Méthodes d'extraction de l'information spatiale et de classification en imagerie de télédétection : Applications à la cartographie thématique de la région d'Agadir (Maroc)*, Thèse de doctorat, Université Toulouse 3, Toulouse.
- IMMITZER Markus, VUOLO Francesco & ATZBERGER Clement, (2016), « First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe », *Remote Sensing*, n°8(3), 166. Disponible en ligne : <https://doi.org/10.3390/rs8030166> [dernier accès avril 2026].
- KADDOUR DRIZI Houssein, (2022), *Réseau neuronal convolutif avec données d'apprentissage augmentées pour détecter les obstacles dans les systèmes de pilotage de trains autonomes*, Mémoire de Master, Université du Québec à Montréal.
- KONÉ Mohamed, SANOGO Tinzanga, SIDIBÉ Sidiki & MARIKO Zakaridia, (2026), « Performance et limites des workflows de classification d'images satellitaires dans le contexte Ouest Africain : Comparaison de ENVI, ERDAS

- Imagine et Orfeo ToolBox (OTB) », *European Scientific Journal, ESJ*, n°22(2). Disponible en ligne : <https://doi.org/10.19044/esj.2026.v22n2p128> [dernier accès mars 2026].
- LAMBERT Marie-Julie, TRAORÉ Pierre Sibiry et *al.*, (2018), « Estimating smallholder crops production at village level from Sentinel-2 time series in Mali's cotton belt », *Remote Sensing of Environment*, n°216, pp. 647-657. Disponible en ligne : <https://doi.org/10.1016/j.rse.2018.06.036> [dernier accès avril 2026].
- LANDIS Richard & KOCH Gary, (1977), « A one-way components of variance model for categorical data », *Biometrics*, n°33(4), pp. 671-679. <https://doi.org/10.2307/2529465> [dernier accès avril 2026].
- LINBONGUI Gerard Emmanuel, (2016), *Apport de l'imagerie satellitaire optique dans le suivi des risques de pollution manganésière au Gabon : Cas de Moanda*, mémoire de Master, Université Omar Bongo.
- MELGANI Farid & BRUZZONE Lorenzo, (2004), « Classification of hyperspectral remote sensing images with support vector machines », *IEEE Transactions on Geoscience and Remote Sensing*, n°42(8), pp. 1778-1790. Disponible en ligne : <https://doi.org/10.1109/TGRS.2004.831865> [dernier accès mars 2026].
- MIHINDOU MIHINDOU Glenn F., (2024), *Impacts de l'urbanisation sur l'hydrogéomorphologie urbaine de Mouila*, Mémoire de Master, Université Omar Bongo.
- MONDAL Arun, KUNDU Sananda, CHANDNIHA Drsuresndra, SHUKLA Rituraj & MISHRA Prabhash, (2012), « Comparison of support vector machine and maximum likelihood classification technique using satellite imagery », *International Journal of Remote Sensing and GIS*, n°1, pp. 116-123. [dernier accès avril 2026].
- MUSTAPHA Muzaimi, LIM Hwee San & MAT Jafri, (2010), « Comparison of neural network and maximum likelihood approaches in image classification », *Journal of Applied Sciences*, n°10(22), pp. 2847-2854. Disponible en ligne : <https://doi.org/10.3923/jas.2010.2847.2854> [dernier accès avril 2026].
- NZIGOU BOUCKA Farrel, OBAME Conan Vassily et *al.*, (2021), « Cartographie de l'occupation du sol du Gabon en 2015-Changements entre 2010 et 2015 », *Revue Française de Photogrammétrie et de Télédétection*, n°223, pp. 118-128. Disponible en ligne : <https://doi.org/10.52638/rfpt.2021.567> [dernier accès mars 2026].
- OBREGÓN María Ángeles, RODRIGUES Gonçalo et *al.*, (2019), « Validation of ESA Sentinel-2 L2A Aerosol Optical Thickness and Columnar Water Vapour during 2017-2018 », *Remote Sensing*, n°11(14), 1649. Disponible en ligne : <https://doi.org/10.3390/rs11141649> [dernier accès mars 2026].
- OZDOGAN Mutlu, YANG Yang, ALLEZ George & CERVANTES Chelsea, (2010), « Remote Sensing of Irrigated Agriculture : Opportunities and Challenges », *Remote Sensing*, n°2(9), pp. 2274-2304. Disponible en ligne : <https://doi.org/10.3390/rs2092274> [dernier accès mars 2026].



- PELLETIER Charlotte et al., (2017), « Effect of Training Class Label Noise on Classification Performances for Land Cover Mapping with Satellite Image Time Series », *Remote Sensing*, n°9(2). Disponible en ligne : <https://doi.org/10.3390/rs9020173> [dernier accès mars 2026].
- ROUIBAH Khiredine & BELABBAS Moussa, (2020), « Applying Multi-Index approach from Sentinel-2 Imagery to Extract Urban Area in dry season (Semi-Arid Land in North East Algeria) », *Revista de Teledetección*, n°56. Disponible en ligne : <https://doi.org/10.4995/raet.2020.13787> [dernier accès mars 2026].
- SAVARY Serge, WILLOCQUET Laetitia, PETHYBRIDGE Sarah Jane, ESKER Paul, MCROBERTS Neil & NELSON Andy, (2019), « The global burden of pathogens and pests on major food crops », *Nature Ecology & Evolution*, n°3(3), pp. 430-439. Disponible en ligne : <https://doi.org/10.1038/s41559-018-0793-y> [dernier accès mars 2026].
- SEGARRA Joel, BUCHAILLOT Maria, ARAUS Jose & KEFAUVER Shawn, (2020), « Remote Sensing for Precision Agriculture : Sentinel-2 Improved Features and Applications », *Agronomy*, n°10(5). Disponible en ligne : <https://doi.org/10.3390/agronomy10050641> [dernier accès mars 2026].
- SULTAN Benjamin, Lalou Richard, Amadou Sanni Mouftaou, Oumarou Amadou, Soumaré Mame Arame, ROUDIER Philippe & TRAORÉ Seydou, (2015), « Chapitre 10. Les impacts du changement climatique sur les rendements agricoles en Afrique de l'Ouest », *Les sociétés rurales face aux changements climatiques et environnementaux en Afrique de l'Ouest*, IRD Éditions, Marseille, pp. 209-225. <https://doi.org/10.4000/books.irdeditions.9773> [dernier accès mars 2026].
- TRAN Annelise, DAUDÉ Éric & CATRY Thibault, (2022), *Téledétection et modélisation spatiale : Applications à la surveillance et au contrôle des maladies liées aux moustiques*, Versailles, Editions Quae.
- WU Nitu, CRUSIOL Luís Guilherme Teixeira, LIU Guixiang, WUYUN Deji & HAN Guodong, (2023), « Comparing machine learning algorithms for pixel/object-based classifications of semi-arid grassland in northern china using multisource medium resolution imageries », *Remote Sensing*, n°15(3). Disponible en ligne : <https://doi.org/10.3390/rs15030750> [dernier accès mars 2026].
- XU Hanqiu, (2006), « Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery », *International Journal of Remote Sensing*, n°27(14), pp. 3025-3033. Disponible en ligne : <https://doi.org/10.1080/01431160600589179> [dernier accès mars 2026].
- ZHA Yong, GAO Jay, & NI Shaoxiang, (2003), « Use of normalized difference built-up index in automatically mapping urban areas from TM imagery », *International Journal of Remote Sensing*, n°24(3), pp. 583-594. Disponible en ligne : <https://doi.org/10.1080/01431160304987> [dernier accès mars 2026].



Crédit Photo de couverture
« Croisement à La Lopé », août 2022
Fuzio'Imag.ga

Composition : CNM Éditions
Graphisme : Efry Trytch Mudumumbula
Pour le compte du Groupe CRA
Conception : Crépin Bihoundou Ella
Dépôt légal : Juin 2026

Cahier De La Recherche Africaine

REVUE PLURIDISCIPLINAIRE : LETTRES, ARTS ET SCIENCES
HUMAINES

Université Omar Bongo



TOGETHER WE REACH THE GOAL

Revue indexée

Scientific Journal Impact Factor (SJIF)

<https://sjifactor.com/passport.php?id=23299>

Impact Factor : 5,338

Année 4 - N°7 - Juil-2026

revue.cra@revue-cra.com

www.revue-cra.com

ISSN : 2958-5805 (E)

2958-5813 (P)

Tel(s) : (+241) 66 600 380 / (+33) 6 474 897 81
cnmeditions.gab@gmail.com – 10.000f/15,24€



ISBN : 978-2-494270-20-6



9 782494 270206