

ISSN-P : 2312-7031
ISSN-L : 3078-8234

FACULTE DES SCIENCES DE L'HOMME ET DE LA SOCIÉTÉ

ANYASÃ



Revue des Lettres et Sciences Humaines

Laboratoire de Recherche sur la Dynamique des Milieux et des Sociétés

Université de Lomé

Numéro 18
Juin 2025

ANYASÃ

Revue des Lettres et Sciences Humaines

Université de Lomé

ISSN-P : 2312-7031 ; ISSN-L : 3078-8234

URL de la revue : <https://www.revue-anyasa.org>

Bases de référencement



ADMINISTRATION ET REDACTION DE ANYASÁ

Revue des Lettres et Sciences Humaines
Laboratoire de Recherches sur la Dynamique des Milieux et des Sociétés
Université de Lomé

Directeur administratif de la rédaction : Professeur Messan VIMENYO

Comité scientifique et de lecture

Professeur Yaovi AKAKPO (Université de Lomé)
Professeur Mahamadé SAVADOGO (Université de Ouagadougou)
Professeur Augustin K. DIBI (Université Félix Houphouët-Boigny)
Professeur Lazare POAME (Université Alassane Ouattara)
Professeur Marc Louis ROPIVIA (Université Omar Bongo)
Professeur Charles Zakarie BOAWO (Université Marien Ngouabi)
Professeur Issa Djarangar DJITA (Université de Moundou)
Professeur Azoumana OUATTARA (Université Alassane Ouattara)
Professeur Paul ANOH (Université Félix Houphouët-Boigny)
Professeur Delali Komivi AVEGNON (ENS d'Atakpamé)
Professeur Komi N'KERE (Université de Lomé)
Professeur Benjamin ALLAGBE (Université d'Abomey Calavi)
Monsieur Ludovic Baïsserné PALOU, Maître de Conférences (Université de Pala)
Monsieur Pessièzoum ADJOSSI, Maître de Conférences (Université de Lomé)
Monsieur Iléri DANDONOUGBO, Maître de Conférences (Université de Lomé)
Monsieur Nayondjoa KONLANI, Maître de Conférences (Université de Lomé)
Madame Koko Zébéto HOUEDAKOR, Maître de Conférences (Université de Lomé)
Monsieur Koffi KPOTCHOU, Maître de Conférences (Université de Lomé)
Monsieur Kodzo KPOFFON, Maître de Conférences (Université de Lomé)
Monsieur Eyanah ATCHOLE, Maître de Conférences (ENS d'Atakpamé)

Secrétaire de rédaction : Koku-Azonko FIAGAN (MC), Tel : +228 99762908, E-mail : azonkokoku@gmail.com

Contact :

BP. 1515, Lomé

Tél. : +228 90833419 / 90192589

E-mail : revue.anyasa@gmail.com ou anyasa@revue-anyasa.org

<p>A ces membres du comité scientifique, s'ajoutent d'autres personnes ressources consultées occasionnellement en fonction des articles à évaluer</p>

Éditorial

Le mot **Anyasa** prononcé Anyásã, à ne pas confondre avec ah̄hlō, désigne en éwé « intelligence » ou « connaissance ». Dans les textes bibliques, anyásã est mis en rapport synonymique avec núnya « savoir ». Pour le caractère scientifique des travaux et la dimension universelle des recherches, le vocable a été retenu pour nommer cette Revue des Lettres et Sciences humaines que le *Laboratoire de Recherche sur la Dynamique des Milieux et des Sociétés (LARDYMES)* se propose de faire paraître deux numéros par an. La naissance de cette revue scientifique s'explique par le besoin pressant de pallier le déficit de structure de publication spécialisés en Lettres et Sciences humaines dans les universités francophones de l'Afrique. C'est précisément pour parvenir à cette vision holistique de la recherche (et non seulement de ses résultats, dont les plus évidents sont les publications, mais aussi de son contexte), que nous éditons depuis 2014 la revue Anyasa afin que chaque chercheur en sciences sociales trouve désormais un espace pour diffuser les résultats de ses travaux de recherche et puisse se faire évaluer pour son inscription sur les différentes listes d'aptitudes des grades académiques de son université.

Charte d'éthique

Pour veiller à l'intégrité des travaux et de la diffusion des recherches scientifiques, la revue Anyasa applique les règles éthiques de la présente charte. Nous encourageons les membres du comité scientifique et de lecture, les contributeurs et les évaluateurs à les respecter.

Engagements de la revue

Le comité de rédaction a pour priorité l'amélioration de la revue anyasa, ainsi que la publication et la diffusion en ligne d'un contenu scientifique concis, exigeant et éthique.

Rôles des évaluateurs

Les évaluateurs sont sélectionnés pour leur expertise scientifique. Ils sont chargés d'évaluer les manuscrits sur leur seul contenu, sans distinction de race, de sexe, de convictions religieuses, de nationalité, d'affiliation universitaire. Les avis rendus par les évaluateurs doivent être objectifs. Les évaluateurs sont tenus de signaler tous les articles ayant un rapport de similitude avec l'article soumis à la revue.

Publication

Les auteurs autorisent la diffusion de leur article au format papier et numérique sur le site web de la revue. Les auteurs garantissent à l'éditeur de l'originalité de leur contribution et lui assurent la jouissance entière et libre des droits ainsi cédés. Si leur article est co-signé par plusieurs auteurs, l'auteur principal doit être assuré de l'accord des co-auteurs au regard de la cession de droits. Les auteurs s'engagent également à avoir pris soin d'éviter tout plagiat.

AVIS AUX AUTEURS

1. Note aux contributeurs

« ANYASA » revue des lettres et sciences humaines, publie des articles originaux, rédigés en français, non publiés auparavant et non soumis pour publication dans une autre revue. Les normes qui suivent sont conformes à celles adoptées par le Comité Technique Spécialisé (CTS) de Lettres et sciences humaines/CAMES (cf. dispositions de la 38e session des consultations des CCI, tenue à Bamako du 11 au 20 juillet 2016). Les contributeurs doivent s'y conformer.

1.1. Les manuscrits

Un projet de texte soumis à évaluation, doit comporter un titre (Times New Romans, taille 12, Lettres capitales, Gras), la signature (Prénom(s) et NOM (s) de l'auteur ou des auteurs, l'institution d'attache), l'adresse électronique de (des) auteur(s), le résumé en français (250 mots), les mots-clés (cinq), le résumé en anglais (du même volume), les keywords (même nombre que les mots-clés). Le résumé doit synthétiser la problématique, la méthodologie et les principaux résultats.

Le manuscrit doit respecter la structuration habituelle du texte scientifique : Introduction (Problématique, Hypothèse compris) ; Approche méthodologie ; Résultats ; Analyse des Résultats ; Discussion ; Conclusion ; Références bibliographiques (s'il s'agit d'une recherche expérimentale ou empirique).

Les notes infrapaginales, numérotées en chiffres arabes, sont rédigées en taille 10 (Times New Roman). Réduire au maximum le nombre de notes infrapaginales. Ecrire les noms scientifiques et les mots empruntés à d'autres langues que celle de l'article en italique (*Adansonia digitata*).

Le volume du projet d'article (texte à rédiger dans le logiciel word, Times New Romans, taille 12, interligne 1.5) doit être de 30 000 à 40 000 caractères (espaces compris).

Les titres des sections du texte doivent être numérotés de la façon suivante :

1. Premier niveau, premier titre (Times 12 gras)

1.1. Deuxième niveau (Times 12 gras italique)

1.2.1. Troisième niveau (Times 11 gras, italique)

1.2.2. Les illustrations

Les tableaux, les cartes, les figures, les graphiques, les schémas et les photos doivent être numérotés (numérotation continue) en chiffres arabes selon l'ordre de leur apparition dans le texte. Ils doivent comporter un titre concis, placé au-dessus de l'élément d'illustration (centré). La source (centrée) est indiquée en-dessous de l'élément d'illustration (Taille 10). La source (centrée) est indiquée en dessous de l'élément d'illustration (Taille 10). Ces éléments d'illustration doivent être : annoncés, insérés puis commentés dans le corps du texte.

La présentation des illustrations : figures, cartes, graphiques, etc. doit respecter le miroir de la revue. Ces documents doivent porter la mention de la source, de l'année et de l'échelle (pour les cartes).

2. Notes et références

2.1. Les passages cités sont présentés entre guillemets. Lorsque la phrase citant et la citation dépasse trois lignes, il faut aller à la ligne, pour présenter la citation (interligne 1) en retrait, en diminuant la taille de police d'un point.

2.2. Les références de citation sont intégrées au texte citant, selon les cas, ainsi qu'il suit :

- Initiale (s) du Prénom ou des Prénoms et Nom de l'auteur, année de publication, pages citées (B. A. Sy. 2008, p. 18) ;
- Initiale (s) du Prénom ou des Prénoms et Nom de l'Auteur (année de publication, pages citées).

Exemples :

- En effet, le but poursuivi par M. Ascher (1998, p. 223), est « d'élargir l'histoire des mathématiques de telle sorte qu'elle acquière une perspective multiculturelle et globale (...) »
- Pour dire plus amplement ce qu'est cette capacité de la société civile, qui dans son déploiement effectif, atteste qu'elle peut porter le développement et l'histoire, S. B. Diagne (1991, p. 2) écrit

Qu'on ne s'y trompe pas : de toute manière, les populations ont toujours su opposer à la philosophie de l'encadrement et à son volontarisme leurs propres stratégies de contournements. Celles-là, par exemple, sont lisibles dans le dynamisme, ou à tout le moins, dans la créativité dont sait preuve ce que l'on désigne sous le nom de secteur informel et à qui il faudra donner l'appellation positive d'économie populaire. - Le philosophe ivoirien a raison, dans une certaine mesure, de lire, dans ce choc déstabilisateur, le processus du sous-développement.

Ainsi qu'il le dit : Le processus du sous-développement résultant de ce choc est vécu concrètement par les populations concernées comme une crise globale : crise socio-économique (exploitation brutale, chômage permanent, exode accéléré et douloureux), mais aussi crise socioculturelle et de civilisation traduisant une impréparation socio-historique et une inadaptation des cultures et des comportements humains aux formes de vie imposées par les technologies étrangères. (S. Diakité, 1985, p. 105).

2.3. Les sources historiques, les références d'informations orales et les notes explicatives sont numérotées en continue et présentées en bas de page.

2.4. Les divers éléments d'une référence bibliographique sont présentés comme suit : Nom et Prénom (s) de l'auteur, Année de publication, Titre, Lieu de publication, Editeur, pages (p.) pour les articles et les chapitres d'ouvrage. Le titre d'un article est présenté entre guillemets, celui d'un ouvrage, d'un mémoire ou d'une thèse, d'un rapport, d'une revue ou d'un journal est présenté en italique. Dans la zone Editeur, on indique la Maison d'édition (pour un ouvrage), le Nom et le numéro/volume de la revue (pour un article). Au cas où un ouvrage est une traduction et/ou une réédition, il faut préciser après le titre le nom du traducteur et/ou l'édition (ex : 2nde éd.).

2.5. Les références bibliographiques sont présentées par ordre alphabétique des noms d'auteur.

Par exemple :

Références bibliographiques

AMIN Samir, 1996, Les défis de la mondialisation, Paris, L'Harmattan, société, Paris, Gallimard, 352 p.

BERGER Gaston, 1967, L'homme moderne et son éducation, Paris, PUF. DIAGNE Souleymane Bachir, 2003, « Islam et philosophie. Leçons d'une rencontre », Diogène, 202, p. 145-151.

DIAKITE Sidiki, 1985, Violence technologique et développement. La question africaine du développement, Paris, L'Harmattan, 156 p.

Sommaire

Géographie

EFFETS DE LA SPECULATION IMMOBILIERE SUR LA MOBILITE RESIDENTIELLE DANS LE GRAND ABIDJAN EN COTE D'IVOIRE.....	p. 1-14
<i>Kouakou Tehua Pierre DEKI, T. Benoît DANVIDE, Kossiwa ZINSOU-KLASSOU</i>	
IMPLICATIONS SOCIO-ECONOMIQUES ET ENVIRONNEMENTALES DU MARAICHAGE DANS LA PREFECTURE DES LACS AU SUD-EST DU TOGO.....	p.15-32
<i>Edmond Kokou KOUNOUGNA, Abasse SEBABI, Tchégnon ABOTCHI</i>	
COLLECTIVITE TERRITORIALE DU GOLFE 7 FACE AUX DEFIS D'ACCESSIBILITE AUX EQUIPEMENTS SOCIO-ECONOMIQUES DE BASE ET DE BONNE GOUVERNANCE.	p.33-45
<i>Sélom Luc AFANTCHAO, Koku-Azonko FIAGAN, Edinam KOLA</i>	
LA CHAINE DE VALEUR DU MANIOC ET AUTONOMISATION FINANCIERE DE SES ACTEURS DANS LE DISTRICT AUTONOME DE YAMOOUSSOUKRO (COTE D'IVOIRE)	p.46-63
<i>Souleymane SORO, Achille Roger TAPE, Kouadio Marus N'GUESSAN, Arsène DJAKO</i>	
PRIVATISATION, DECENTRALISATION REGIONALE ET ENTRETIEN ROUTIER EN MILIEU RURAL : CAS DE LA REGION DE LA BAGOUE AU NORD DE LA COTE D'IVOIRE)	p. 64-81
<i>Kouadio Joseph KRA</i>	
ÉTUDE COMPARATIVE DES ALGORITHMES DE MACHINE LEARNING (RF, SVM ET CART) POUR LA CARTOGRAPHIE DE L'OCCUPATION DU SOL PAR TÉLÉDÉTECTION OPTIQUE DANS LA ZONE DU SINE SALOUM (SENEGAL).....	p. 82-109
<i>Labaly TOURÉ, Amandine Carine NJEUGEUT MBIAFEU, Marc YOUAN TA, Moussa SOW et Jean Patrice JOURDA</i>	
RESSOURCES NATURELLES ET CONFLITS DANS L'EST DU CAMEROUN : EXPLORATION DES APPROCHES INNOVANTES DES FEMMES POUR LA PRESERVATION DE LA PAIX ET LA GESTION DURABLE DES RESSOURCES.....	p. 110-127
<i>Adrien Narcisse DEUDJUI, Lila Reni BIBRIVEN</i>	

- IMPACTS SOCIO-SANITAIRE ET ENVIRONNEMENTAL
DES EPAVES DES VOITURES D'OCCASION DANS LA
VILLE DE KARA AU NORD DU TOGO.....
*Charifou TAIROU FOUSSENI, Assogba GUEZERE, Babénoun
LARE* p. 128-139
- CONSÉQUENCES ENVIRONNEMENTALES ET
SANITAIRES DE LA GESTION DES EAUX USÉES À
BOUNDIALI (NORD DE LA CÔTE D'IVOIRE)
Brahima CISSE, Idrissa SARAMBE, Sindou Amadou KAMAGATE p. 140-151
- EFFET PONT ET PRATIQUES DE MOBILITES SPATIALES
DES POPULATIONS AU DEPART ET VERS JACQUEVILLE
EN CÔTE D'IVOIRE.....
Djanin Raphaël GNANBE p. 152-172
- PROBLEMES ENVIRONNEMENTAUX ET SANITAIRES
LIÉS A LA PRATIQUE AGRICOLE DANS LE BAS-FOND DE
NATIO-KOBADARA DANS LA VILLE DE KORHOGO.....
*Moussa COULIBALY, Nafolo Drissa YEO, Rosalie Gazalo
ZOHOURE* p. 173-191
- LA NOIX DE CAJOU : ACTEURS ET PROCESSUS
D'ACHEMINEMENT DES ZONES DE PRODUCTION DE
BOUNDIALI VERS LE PORT D'ABIDJAN
Koulai Hervé YRO, Amara KONE p. 192-205

Philosophie

- PLÉBISCITE DES COUPS D'ÉTAT EN AFRIQUE : LE
MILITAIRE, HOMME PROVIDENTIEL ?.....
Juste Joris TINDY-POATY p. 206-223

Lettres modernes

- DYNAMIQUE LITTÉRAIRE ET EXERCICE DU POUVOIR
DANS LA SOCIÉTÉ AKAN : CAS DE « LA LÉGENDE
BAOULE » EXTRAIT DE "LÉGENDES AFRICAINES" DE
BERNARD DADIE
Mafiani N'Da KOUADIO p. 224-239

Sociologie et anthropologie

- ROLE ET INTÉGRATION DE LA FEMME RURALE DANS
LA VIE SOCIOÉCONOMIQUE FAMILIALE A MADANA AU

TCHAD.....	p. 240-251
<i>Tchago NDIKWE, Marina DOUBE</i>	
INFLUENCE DU GENRE DANS LE DEVELOPPEMENT ET LA DOCUMENTATION DES INNOVATIONS LOCALES POUR LA PROMOTION DE LA SECURITE ALIMENTAIRE ET NUTRITIONNELLE AU NORD-BENIN.....	p. 252-274
<i>Georges DJOHY</i>	

ÉTUDE COMPARATIVE DES ALGORITHMES DE MACHINE LEARNING (RF, SVM ET CART) POUR LA CARTOGRAPHIE DE L'OCCUPATION DU SOL PAR TÉLÉDÉTECTION OPTIQUE DANS LA ZONE DU SINE SALOUM (SENEGAL)

Labaly TOURÉ, Amandine Carine NJEUGEUT MBIAFEU, Marc YOUAN TA, Moussa SOW et Jean Patrice JOURDA

Université du Sine Saloum Elhadj Ibrahima Niass, Sénégal, Centre Universitaire de Recherche Appliquée en Télédétection (CURAT), Unité de Formation et de Recherche des Sciences de la Terre et des Ressources Minières (UFR-STRM), Université Félix Houphouët-Boigny d'Abidjan, Côte d'Ivoire, Université Gaston Berger de Saint-Louis (UGB), Sénégal

Résumé : Les paysages du Sine Saloum, situés dans les régions de Kaffrine, Fatick et Kaolack, ont subi d'importantes transformations sous l'effet des activités humaines et du climat, notamment après les sécheresses des années 1980. Ces mutations ont modifié l'organisation spatiale et les usages du sol, entraînant une reconversion socio-économique des populations locales. La télédétection optique, grâce aux images multispectrales, constitue un outil essentiel pour analyser ces dynamiques et suivre l'évolution de l'occupation et des usages des terres. Cette étude vise à cartographier l'occupation du sol dans le Sine Saloum en exploitant des images Sentinel-2 et des algorithmes de machine learning. Une classification supervisée a été réalisée avec Random Forest (RF), Classification and Regression Trees (CART) et Support Vector Machines (SVM) afin d'identifier six classes : habitat, sol nu, mangrove, zones agricoles, surfaces en eau et terres salées. Les résultats révèlent que RF et CART offrent des précisions globales élevées (99,70 % et 99,59 %), surpassant SVM (97,56 %). Les valeurs de l'indice Kappa ($>0,81$) indiquent une excellente concordance avec les données de validation. Toutefois, SVM présente des limitations, notamment une faible précision du producteur pour les sols nus et des erreurs accrues dans certaines classes. Cette étude confirme la pertinence de RF et CART pour la classification des images Sentinel-2 dans le Sine Saloum pour l'occupation des sols et suggère des améliorations pour SVM. Elle souligne l'apport des algorithmes de machine learning pour la cartographie de l'occupation du sol et propose des pistes d'optimisation pour de futures applications en télédétection optique.

Mots-clés : Machine learning, occupation du sol, télédétection, Sentinel-2, Sine Saloum.

Abstract: The landscapes of the Sine Saloum, in the regions of Kaffrine, Fatick and Kaolack, have undergone major transformations as a result of human activity and climate, particularly after the droughts of the 1980s. These changes have altered spatial organisation and land use, leading to socio-economic conversion among local populations. Optical remote sensing, using multispectral images, is an essential tool for analysing these dynamics and monitoring changes in land use and occupation. The aim of this study is to map land cover in the Sine Saloum using Sentinel-2 images and machine

learning algorithms. A supervised classification was carried out using Random Forest (RF), Classification and Regression Trees (CART) and Support Vector Machines (SVM) to identify six classes: habitat, bare soil, mangroves, agricultural areas, water surfaces and salt land. The results show that RF and CART offer high overall accuracies (99.70% and 99.59%), outperforming SVM (97.56%). The Kappa index values (>0.81) indicate excellent agreement with the validation data. However, SVM has limitations, including low producer accuracy for bare soil and increased errors in some classes. This study confirms the relevance of RF and CART for land cover classification of Sentinel-2 images in the Sine Saloum and suggests improvements for SVM. It underlines the contribution of machine learning algorithms for land cover mapping and suggests avenues of optimisation for future applications in optical remote sensing.

Keywords : Machine learning, land use, remote sensing, Sentinel-2, Sine Saloum

Introduction

La cartographie de l'occupation du sol est un outil crucial pour la gestion durable des ressources naturelles, particulièrement dans des régions écologiquement sensibles comme le Sine Saloum au Sénégal. Située au carrefour de dynamiques climatiques et anthropiques complexes, cette région a connu des transformations significatives de ses paysages au cours des dernières décennies (E. F. Lambin, H. J. Geist et E. Lepers, 2003, p. 205-41). Les sécheresses des années 1980 ont été exacerbées par la pression sur les terres, entraînant des mutations spatiales et une réorganisation des usages du sol (I. Savane, K. M. Coulibaly et P. Gioan, 2001, p. 37-42). Aujourd'hui, dans un contexte de changement climatique global et de reconversion socioprofessionnelle, la nécessité de disposer d'outils précis et efficaces pour suivre ces transformations n'a jamais été aussi pressante.

Cependant, la diversité des paysages et des usages du sol dans le Sine Saloum pose un défi majeur pour la cartographie précise de l'occupation du sol. L'application des algorithmes de classification supervisée pour traiter les images satellites, en particulier celles fournies par les capteurs Sentinel-2, offre une opportunité de surmonter ce défi (M. Drusch et al., 2012, p. 25-36). Néanmoins, la performance de ces algorithmes varie en fonction de la complexité des paysages à cartographier, de la nature des données disponibles mais aussi de l'étendue de la zone d'étude.

Ainsi, la problématique centrale de cette étude repose sur l'évaluation comparative de trois algorithmes d'apprentissage automatique - Random Forest (RF), Support Vector Machine (SVM) et Classification and Regression Tree (CART) - dans la cartographie de l'occupation du sol dans la zone du Sine Saloum. Il s'agit d'analyser les apports de ces méthodes de classification et de voir laquelle peut donner plus de précision pour l'occupation des sols. Cette approche comparative est essentielle, car des études précédentes ont souvent privilégié un seul algorithme pour la classification des images satellitaires, comme le Random Forest ou le SVM (M. Belgiu et L. Drăguț, 2016, p.

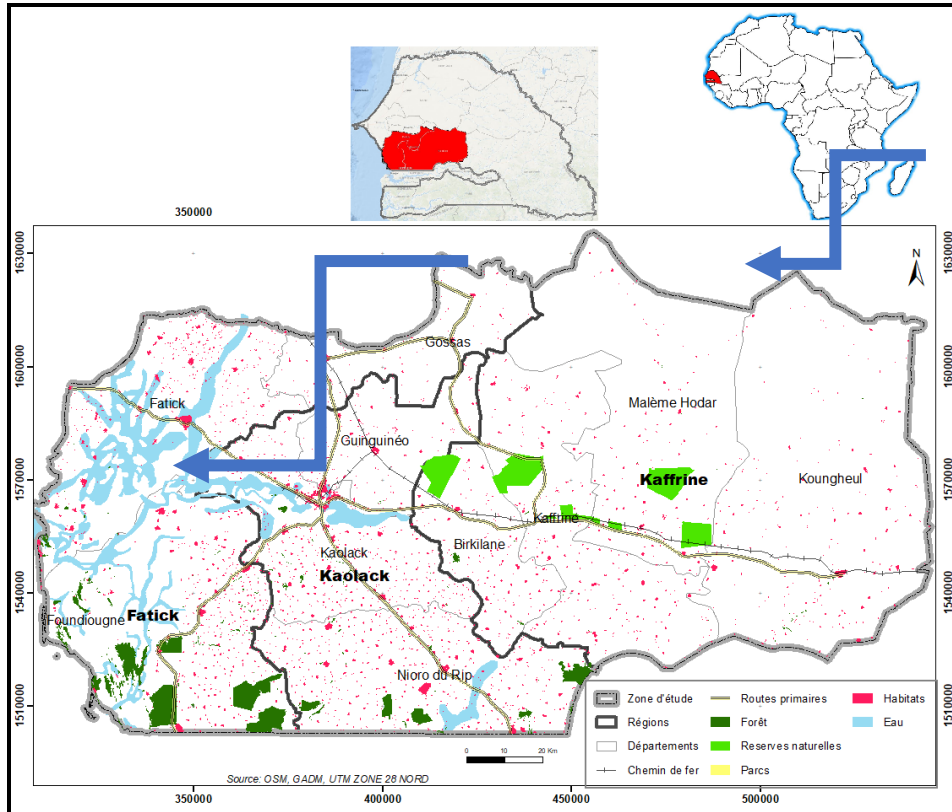
24-31), sans nécessairement tenir compte des performances relatives des autres méthodes dans des environnements géographiques complexes. La littérature montre que le RF a été largement utilisé pour sa robustesse et sa capacité à gérer des données multidimensionnelles (V. F. Rodriguez-Galiano et al., 2012, p. 93-104), tandis que le SVM est reconnu pour sa précision dans la séparation de classes avec des distributions complexes (G. Mountrakis et al., 2011, p. 247-59). Cependant, en fonction des caractéristiques spécifiques du paysage, chaque algorithme peut présenter des performances variables selon les classes retenues. C'est pourquoi une comparaison est cruciale pour déterminer l'algorithme le plus adapté aux particularités spatiales et environnementales du Sine Saloum.

La région du Sine Saloum au Sénégal est une zone géographique d'une importance écologique, culturelle et économique notable. Située entre les latitudes 13.5° et 14.5° N, et les longitudes 16° et 17.5° O, elle s'étend sur la côte ouest du Sénégal, entre les régions de Thiès et de Ziguinchor, avec l'océan Atlantique comme frontière occidentale, créant une juxtaposition unique de zones côtières et d'estuaires (Figure 1). Cette région, située à environ 150 km au sud de Dakar et à la limite sud de Joal, est caractérisée par un labyrinthe d'îles et de rias. Elle constitue la marge septentrionale de la mangrove des Rivières du Sud (J. Bethemont, 2000, p. 95), un écosystème qui s'étend de manière continue le long de la côte atlantique de l'Afrique jusqu'au Libéria.

Le territoire étudié englobe à la fois des zones administratives et éco-géographiques, notamment l'ancien bassin arachidier de Kaolack, qui occupe une large portion du Sine Saloum. Cette région abrite des activités socio-économiques diversifiées où l'agriculture, la pêche et l'élevage jouent un rôle prépondérant. Le delta du Saloum, riche en biodiversité, est notamment reconnu pour ses paysages de mangroves (N. Moreau, 1991, p. 300). Ces écosystèmes sont composés de formations végétales dominées par les palétuviers, organisées en zonage depuis les eaux libres vers les terres fermes. Les espèces de mangroves présentes incluent *Rhizophora racemosa* et *R. harisonnii*, soumises à l'influence directe des marées, ainsi que *Rhizophora mangle*, *Avicennia africana*, *Laguncularia racemosa* et *Conocarpus erectus*, avec une présence variable selon leur tolérance aux marées et aux conditions de salinité.

Le Sine Saloum se distingue par une mosaïque de paysages comprenant mangroves, savanes, rivières et îles, formant un réseau complexe d'estuaires et de lagunes qui abrite une biodiversité exceptionnelle. Les mangroves, en particulier, jouent un rôle crucial en tant que nurserie pour de nombreuses espèces marines, tandis que la faune terrestre comprend une diversité d'oiseaux, de mammifères et de reptiles adaptés aux conditions écologiques spécifiques de la région (D. M. Alongi, 2008, p. 1-13).

Figure 1 : Situation géographique de la zone d'étude

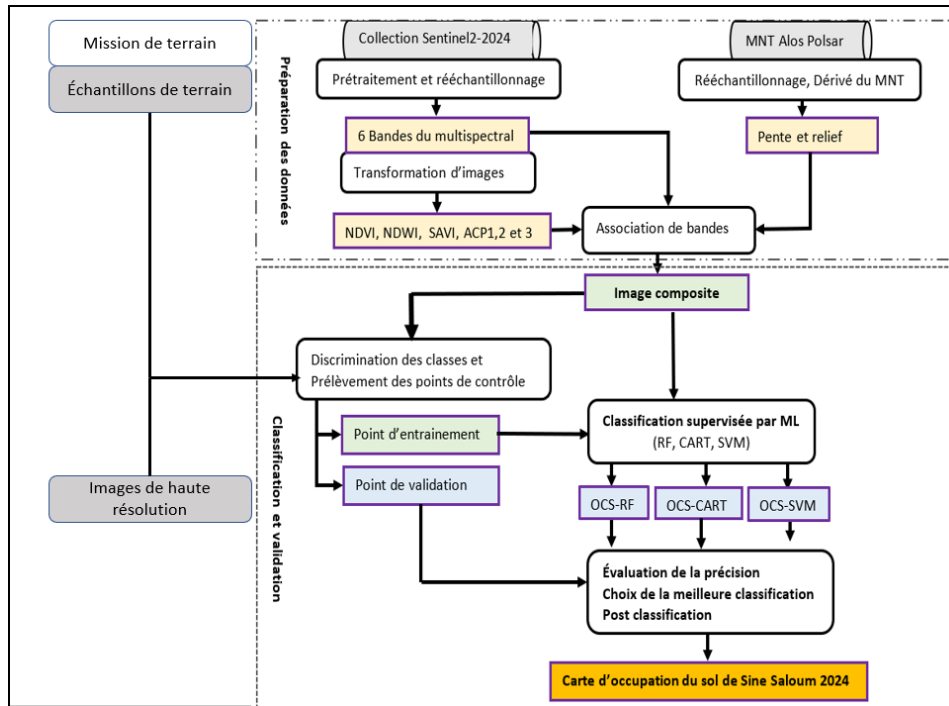


L'économie locale est dominée par la pêche, une activité vitale pour les communautés dépendantes des ressources marines et estuariennes, mais aussi par l'agriculture, l'élevage et le tourisme. Cependant, la région du Sine Saloum fait face à des défis majeurs, notamment la dégradation de l'environnement, la surexploitation des ressources marines et les impacts des changements climatiques. La mise en œuvre d'initiatives de conservation, de gestion durable des ressources et de sensibilisation est essentielle pour préserver cet écosystème fragile et garantir la durabilité à long terme de la région. Notre terrain d'étude comprend les trois régions administratives de Kaolack, Fatick et Kaffrine

1. Approche méthodologie

L'approche retenue pour cartographier l'occupation du sol en 2024 par machine learning depuis google earth engine, repose sur la démarche suivante qui va de la préparation des données à la classification (Figure 2).

Figure 2 : Processus de cartographie des unités d'occupation du sol par les algorithmes de Machine Learning



1.1. Acquisition des images

Les données utilisées dans cette étude comprennent des images multispectrales Sentinel-2 de l'année 2024, qui offrent une résolution spatiale de 10 mètres. Ces images comportent des bandes du multispectral, couvrant des longueurs d'onde spécifiques, particulièrement adaptées à la cartographie de l'occupation du sol, chacune apportant des informations précieuses sur les caractéristiques de la végétation, des surfaces en eau, des sols nus, et d'autres éléments du paysage.

En complément des images optiques, cette étude intègre également un modèle numérique de terrain (MNT) issu des données Alos PALSAR, initialement à une résolution de 12,5 mètres et rééchantillonné à 10 mètres pour assurer une meilleure cohérence avec les images Sentinel-2. Ce MNT fournit une représentation détaillée de la topographie de la région du Sine Saloum, ajoutant une dimension altimétrique qui permet d'améliorer la précision de la classification des différentes classes d'occupation du sol.

L'intégration de ces données multispectrales et topographiques permet d'exploiter pleinement la richesse des informations disponibles, tout en bénéficiant de la haute résolution spatiale offerte par les deux ensembles de données. Cette combinaison

constitue une base solide pour l'application des algorithmes d'apprentissage automatique dans le cadre de cette étude comparative (M. Li et al., 2014, p. 389-411).

1.2. Préparation des données

1.2.1. Prétraitement des images

Pour obtenir des résultats fiables, des corrections géométriques et radiométriques ont été effectuées sur les images Sentinel-2. Concrètement, cela inclut la rectification géométrique pour aligner les images sur un système de coordonnées géographiques standard et la correction radiométrique pour ajuster les variations de luminosité causées par l'atmosphère et les conditions d'éclairage. Google Earth Engine permet la sélection des images en fonction de critères de localisation, de période, et de couverture nuageuse. La présence importante de nuages peut altérer la qualité des résultats en masquant des parties de l'image. Ainsi, pour cette étude, nous avons utilisé le composite annuel de 2024 de Sentinel-2 (image médiane), sélectionné pour sa couverture nuageuse inférieure à 1% afin de minimiser ces effets (M. A. C. Njeugeut et al., 2023, p. 310-32).

1.2.2. Création de l'image composite

L'intégration de multiples types de données dans une image composite permet de capturer une gamme plus large de caractéristiques spectrales et spatiales, ce qui améliore la capacité de discrimination entre différentes classes d'occupation du sol (S. L. Powell et al., 2007; G. M. Foody, 2002, p. 185-201).

Les données utilisées pour cette étude proviennent des images multispectrales Sentinel-2 de l'année 2024, offrant une résolution spatiale de 10 mètres. L'image composite finale est constituée de l'ensemble des bandes multispectrales rééchantillonnées, des indices spectraux (NDVI, NDWI, SAVI), des dérivés topographiques (pente, relief), et des trois premières composantes principales de l'ACP. Cette combinaison de variables permet une classification robuste et précise de l'occupation du sol en exploitant à la fois les informations spectrales, topographiques et statistiques.

Les bandes spectrales sélectionnées incluent le bleu (B2 : 490 nm), le vert (B3 : 560 nm), le rouge (B4 : 665 nm), le proche infrarouge (B8 : 842 nm), ainsi que deux bandes du moyen infrarouge (B11 : 1610 nm et B12 : 2190 nm), rééchantillonnée à une résolution de 10 mètres pour garantir l'uniformité des données depuis Google earth engine, ce qui est important pour une classification précise. Ces bandes sont particulièrement pertinentes pour l'analyse de la végétation, des surfaces en eau et des sols nus, qui sont des composantes clés de l'occupation du sol dans la région du Sine Saloum. Les bandes du visible (bleu, vert et rouge) permettent une discrimination fine des différents types de couverture terrestre et des caractéristiques des surfaces, tandis que les bandes du proche infrarouge sont sensibles à la réflectance de la végétation, et les bandes du moyen infrarouge sont efficaces pour distinguer les sols nus, l'humidité des sols et les zones en eau (M. Drusch et al., 2012, p. 25-36). L'intégration des paramètres topographiques

dérivés du modèle numérique de terrain (MNT) Alos PALSAR rééchantillonné à 10m, ajoute une dimension supplémentaire à la classification de l'occupation du sol.

Les indices spectraux et les 3 premières composantes de l'analyse en composante principale intégrées dans l'image composite jouent un rôle crucial dans la classification de l'occupation du sol en fournissant des informations supplémentaires sur l'état de la végétation, la présence d'eau, et les conditions du sol (A. R. Huete, 1988, p. 295-309). Le NDVI est largement utilisé pour évaluer la densité et l'état de la végétation, le NDWI est utilisé pour détecter les surfaces en eau et le SAVI est particulièrement efficace dans les zones où la végétation est clairsemée, et où l'exposition du sol pourrait fausser les résultats du NDVI. L'ACP1 capture les variations dominantes dans les données, souvent associées à la végétation et aux sols, l'ACP2 souligne les différences entre les surfaces en eau et les autres types de couverture et l'ACP3 fournit une perspective supplémentaire, souvent liée aux variations topographiques.

Cette méthodologie détaillée offre une approche rigoureuse pour la classification de l'occupation du sol dans la zone du Sine Saloum, intégrant des données multispectrales, des indices spectraux, et des variables topographiques, tout en optimisant la réduction de la dimensionnalité à travers l'ACP. Les algorithmes de machine learning utilisés dans cette étude exploitent cette riche image composite pour fournir une classification précise et informée des différentes classes d'occupation du sol.

L'utilisation des différentes bandes et de néocanaux a permis de réaliser une image composite. Cependant, les bandes n'ont pas les mêmes poids et leur contribution aux résultats de la classification varient en fonction de leurs paramètres spectraux et des classes d'occupation (Figure 3).

1.3. Identification et nomenclature des classes d'occupation du sol

1.3.1. Choix des classes d'occupation du sol

Pour une classification précise et représentative de l'occupation du sol dans la région du Sine Saloum, nous avons sélectionné huit classes d'occupation du sol : zone marécageuse, mangrove, végétation naturelle, habitat, terre salée, agriculture, eau, et sols nus (Tableau 1). Le choix de ces classes est fondé sur la différenciabilité des signatures spectrales et leur capacité à représenter fidèlement les caractéristiques écologiques et fonctionnelles de la zone d'étude :

- Zone marécageuse

Les zones marécageuses, souvent caractérisées par des sols saturés d'eau et une végétation émergente, présentent des signatures spectrales distinctes en raison de leur forte teneur en eau et de la combinaison unique de plantes aquatiques et de sols boueux. Les indices comme le NDWI (Normalized Difference Water Index) sont particulièrement efficaces pour détecter ces zones.

- **Mangrove**

Les mangroves sont des écosystèmes côtiers importants qui fournissent des habitats pour diverses espèces marines et terrestres et protègent les côtes contre l'érosion. Les mangroves possèdent des signatures spectrales distinctives en raison de la présence de palétuviers avec des canopées denses et des caractéristiques d'humidité élevées. Les indices comme le NDVI (Normalized Difference Vegetation Index) et le SAVI (Soil Adjusted Vegetation Index) permettent de différencier efficacement les mangroves des autres types de végétation.

- **Végétation naturelle**

La végétation naturelle, incluant les forêts et les broussailles, a des signatures spectrales distinctes grâce à la variation de la biomasse végétale et de la structure de la canopée. Le NDVI est particulièrement utile pour identifier et différencier cette classe en raison de la forte réflectance dans le proche infrarouge. Cette classe représente les zones non perturbées ou moins influencées par l'activité humaine, essentielles pour la conservation de la biodiversité.

- **Habitat**

Les zones urbaines ou les habitats humains présentent des signatures spectrales distinctes en raison de la présence de matériaux bâtis, de routes et d'autres surfaces artificielles. Ces surfaces ont des propriétés spectrales différentes des surfaces naturelles, ce qui est détectable avec les bandes spectrales visibles et du proche infrarouge. Les habitats humains comprennent les infrastructures et les zones résidentielles qui modifient le paysage naturel et influencent les processus écologiques.

- **Terre Salée**

Les terres salées, souvent présentes dans les zones côtières et les salines, ont des signatures spectrales uniques en raison de leur haute teneur en sels et leur texture superficielle. Les indices comme le SAVI et les dérivés du MNT (modèle numérique de terrain) permettent de détecter ces zones. Ces terres sont influencées par des conditions salines spécifiques, impactant la végétation et l'utilisation du sol.

- **Agriculture**

Les terres agricoles, telles que les champs cultivés, présentent des signatures spectrales différentes en raison de la gestion régulière des sols et des variations saisonnières dans la végétation. Les indices spectraux comme le NDVI peuvent être utilisés pour identifier les cultures et les zones de culture. L'agriculture représente une utilisation humaine intensive des sols et a des implications importantes pour la gestion des ressources naturelles et la conservation.

- **Eau**

Les surfaces d'eau, telles que les lacs, les rivières et les étangs, ont des signatures spectrales distinctes en raison de leur faible réflectance dans le proche infrarouge et leur

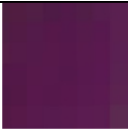
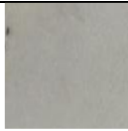
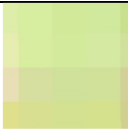
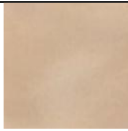



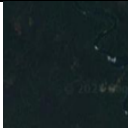


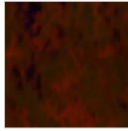
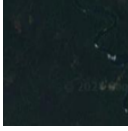




haute réflectance dans le bleu et le vert. Le NDWI est particulièrement efficace pour identifier les surfaces aquatiques. Les zones aquatiques jouent un rôle vital dans les écosystèmes, fournissant de l'habitat pour la faune aquatique et influençant le climat local.

- **Sols nus**

Les sols nus présentent des signatures spectrales distinctes en raison de leur texture et de leur absence de couverture végétale. Les bandes spectrales visibles et les indices spectraux permettent de différencier les sols nus des autres types de couverture terrestre. Les sols nus, souvent issus de déforestation ou de dégradation, ont des implications sur l'érosion des sols et la perte de biodiversité.

Les huit classes d'occupation du sol choisies pour la classification du Sine Saloum sont basées sur la différenciabilité des signatures spectrales et leur capacité à représenter au mieux les caractéristiques écologiques et fonctionnelles de la région. Chaque classe a été sélectionnée en raison de sa pertinence écologique et de sa signature spectrale unique, ce qui permet une classification précise et significative de l'occupation du sol. La sélection de ces classes assure une couverture complète des divers types de couverture terrestre présents dans la région, facilitant ainsi une analyse détaillée et une gestion efficace des ressources naturelles.

Tableau 1 : Identification et nomenclature des classes d'occupation du sol

Classe d'OCS	Composition colorée Sentinel-2 (B8,B12,B4)	Images de haute résolution	Classe d'OCS	Composition colorée Sentinel-2 (B8,B12,B4)	Images de haute résolution
Zone marécageuse			Sols nus		
Zones salées			Eau		
Habitat			Mangrove		
Végétation naturelle			Agriculture		

1.3.2. Echantillonnage des données

Dans le cadre de la classification de l'occupation du sol pour la région du Sine Saloum, un échantillonnage rigoureux des données a été réalisé pour assurer la précision et la fiabilité des résultats. La procédure d'échantillonnage est détaillée comme suit :

- des échantillons de données ont été collectés sur le terrain, et à partir des images de haute résolution et des images multispectrales Sentinel-2, incluant les indices spectraux (NDVI, NDWI, SAVI), les dérivés du modèle numérique de terrain (relief et pente), et les composantes principales issues de l'analyse en composantes principales (ACP) ;
- ces échantillons ont été soigneusement sélectionnés pour représenter les huit classes d'occupation du sol : zone marécageuse, mangrove, végétation naturelle, habitat, terre salée, agriculture, eau, et sols nus.

Les points d'échantillonnage sont choisis en fonction de leur représentativité par rapport aux différentes classes d'occupation du sol cartographiées (zones urbaines, agricoles, forestières, inondées, etc.). La méthode d'échantillonnage stratifiée aléatoire a été appliquée pour assurer une couverture homogène des différentes classes.

Pour l'entraînement et la validation du modèle de classification, les échantillons ont été divisés en deux ensembles distincts :

- **Ensemble d'Entraînement (70%).** Cet ensemble, représentant 70% des échantillons collectés, a été utilisé pour entraîner les modèles de classification. Les données d'entraînement sont essentielles pour ajuster les paramètres des algorithmes de machine learning (RF, SVM, CART) afin qu'ils apprennent à associer correctement les caractéristiques spectrales et topographiques aux classes d'occupation du sol définies.
- **Ensemble de Validation (30%) :** Les 30% restants des échantillons ont été réservés pour la validation des modèles. Cet ensemble est crucial pour évaluer la performance des modèles entraînés en mesurant leur capacité à prédire correctement les classes d'occupation du sol sur des données qu'ils n'ont pas rencontrées lors de l'entraînement. Cette validation permet d'estimer la précision, le rappel, et la F-mesure des classifications obtenues, offrant ainsi une mesure objective de la performance des modèles.

Après la division des données, un processus de vérification a été réalisé pour s'assurer que les échantillons utilisés étaient correctement représentatifs des classes d'occupation du sol. Cette vérification implique la comparaison des échantillons avec des données de terrain ou des observations indépendantes pour confirmer leur exactitude et leur pertinence.

Le processus d'échantillonnage, de rééchantillonnage et de validation des données est fondamental pour assurer la qualité et la précision de la classification de l'occupation du sol. La division des données en ensembles d'entraînement et de validation, ainsi que la vérification rigoureuse des échantillons, garantissent que les résultats de la classification sont fiables et représentatifs des conditions réelles dans la région du Sine Saloum.

1.4. Classification de l'occupation du sol

La classification de l'occupation du sol est réalisée à l'aide de Google Earth Engine (GEE) en utilisant les algorithmes de machine learning Random Forest (RF), Support Vector Machine (SVM), et Classification and Regression Trees (CART).

1.4.1 Random Forest (RF)

Random Forest est un algorithme d'ensemble basé sur la construction de multiples arbres de décision. Chaque arbre est construit à partir d'un sous-ensemble aléatoire des données et des caractéristiques. Les prédictions de ces arbres sont agrégées pour produire la classification finale. RF est moins sensible au sur-apprentissage grâce à la diversité des arbres, ce qui le rend adapté à des données complexes et bruyantes (L. Breiman, 2001, p. 5-32). De plus, il permet d'évaluer l'importance relative des différentes variables (bandes spectrales, indices, dérivés topographiques) pour la classification, facilitant ainsi l'interprétation des résultats (M. Belgiu et L. Drăguț, 2016, p. 24-31). Enfin, RF fournit généralement une haute précision même dans des environnements de données hétérogènes (V. F. Rodriguez-Galiano et al., 2012, p. 93-104).

1.4.2 Support Vector Machine (SVM)

SVM est un algorithme de classification qui cherche à maximiser la marge entre les classes en trouvant un hyperplan optimal dans un espace de caractéristiques de haute dimension. Les noyaux non linéaires, comme le noyau Radial Basis Function (RBF), peuvent être utilisés pour capturer des relations complexes entre les variables. SVM est particulièrement efficace pour des données avec des dimensions élevées, comme les indices spectraux et les composantes principales (C. J. C. Burges, 1998, p. 121-67). Il peut utiliser des noyaux non linéaires pour modéliser des relations complexes entre les caractéristiques, et est très performant pour les classes minoritaires, ce qui est crucial dans des environnements diversifiés (G. Mountrakis et C. Ogole, 2011, p. 247-59).

1.4.3. Classification and Regression Trees (CART)

CART construit des arbres de décision en divisant les données en sous-groupes basés sur les valeurs des caractéristiques. À chaque nœud de l'arbre, les données sont divisées de manière à minimiser une mesure de pureté, comme l'impureté de Gini ou l'entropie. Les résultats sont facilement interprétables sous forme d'arbres de décision, facilitant la compréhension des critères de classification (1998). CART peut gérer les valeurs

manquantes et les variables catégorielles sans nécessiter un prétraitement complexe, et il est bien adapté pour des relations non linéaires et des interactions complexes entre les variables (W. Loh, 2011, p. 14-23).

1.5. Validation des cartes

L'approche méthodologique utilisée pour valider nos cartes est la validation croisée. La validation croisée est utilisée pour évaluer la performance des modèles. Les données sont divisées en ensembles de formation et de test multiples pour éviter le sur-apprentissage et garantir une évaluation robuste.

1.5.1. Mission terrain

La mission terrain vise à valider les résultats obtenus par télédétection à partir d'images satellitaires et à évaluer la précision des classifications cartographiques en croisant les données de terrain et les cartes d'occupation du sol. Cette validation permet de mesurer l'efficacité des algorithmes de classification automatique et d'identifier d'éventuelles erreurs. La mission terrain a été réalisée à l'aide d'un formulaire mobile online et offline, développé à partir de Kobotoolbox. Les données recueillies comprennent le type d'unité d'occupation du sol, l'emplacement géographique, des photos et une description. Sur chaque point échantillonné, des observations précises sont réalisées pour confirmer la classe d'occupation du sol identifiée par la cartographie. Une comparaison est réalisée entre les observations terrain et les résultats de la classification par télédétection. Une matrice de confusion est générée pour chaque période d'observation afin de mesurer la précision globale, la précision par classe, et l'indice de Kappa. Cela permet d'évaluer la performance des classifications et d'identifier les classes où des erreurs de classification sont fréquentes.

1.5.2. Évaluation de la précision

L'évaluation de la précision des algorithmes de classification est cruciale pour déterminer la fiabilité des résultats produits. Pour ce faire, plusieurs métriques sont utilisées, chacune fournissant des informations distinctes sur la performance des modèles. Voici une description détaillée des principales métriques utilisées pour évaluer la précision :

- **Précision globale**

La précision globale est la proportion de pixels correctement classifiés parmi tous les pixels classifiés dans l'ensemble de validation (Eq.1).

$$\text{Précision Globale} = \frac{\text{Nombre de Pixels Correctement Classifiés}}{\text{Nombre Total de Pixels}}$$

Une haute précision globale indique que le modèle a bien classifié la majorité des pixels. Cependant, elle ne prend pas en compte les erreurs spécifiques aux classes et peut donc masquer des problèmes de classification dans certaines classes.

- **Indice Kappa (κ)**

L'indice Kappa (Eq.2) mesure la concordance entre la classification prévue et la vérité terrain en tenant compte de la classification aléatoire. Il ajuste la précision globale pour les classifications correctes qui pourraient être dues au hasard.

$$K = \frac{Po - Pe}{1 - Pe}$$

Où Po est la précision observée (précision globale) et Pe est la précision attendue (précision basée sur la distribution des classes).

L'indice Kappa varie de -1 (classification totalement incorrecte) à 1 (classification parfaitement correcte). Un Kappa supérieur à 0.8 indique une excellente concordance, tandis qu'un Kappa inférieur à 0.4 suggère que les résultats sont moins fiables.

- **Matrice de Confusion**

La matrice de confusion est un tableau qui compare les classifications prévues par le modèle avec les classifications réelles. Elle présente les résultats sous forme de contingence entre les classes prévues et les classes réelles. La matrice de confusion permet de calculer des métriques spécifiques à chaque classe, comme la précision du producteur et de l'utilisateur, ainsi que d'identifier les erreurs de classification entre les différentes classes.

- **Précision du Producteur (ou Sensibilité)**

La précision du producteur (Eq.3) mesure la capacité du modèle à identifier correctement les pixels d'une classe particulière par rapport au nombre total de pixels qui appartiennent réellement à cette classe.

$$\text{Précision du Producteur} = \frac{\text{Vraies Positives}}{\text{Vraies Positives} + \text{Faux Négatifs}}$$

Cette métrique indique combien de pixels réels d'une classe ont été correctement identifiés par le modèle. Une précision élevée du producteur signifie que le modèle est efficace pour détecter les pixels d'une classe donnée.

- **Précision de l'Utilisateur**

La précision de l'utilisateur (Eq.4) mesure la proportion de pixels correctement classifiés dans une classe par rapport au nombre total de pixels classifiés dans cette classe.

$$\text{Précision de l'Utilisateur} = \frac{\text{Vraies Positives}}{\text{Vraies Positives} + \text{Faux Positifs}}$$

Cette métrique indique combien de pixels classifiés dans une classe sont réellement de cette classe. Une précision élevée de l'utilisateur signifie que les pixels classifiés dans une certaine classe sont généralement corrects. L'évaluation de la précision des algorithmes

de classification à l'aide de ces métriques permet de mesurer la performance globale et spécifique des modèles. La précision globale et l'indice Kappa fournissent des aperçus généraux sur la qualité de la classification, tandis que la matrice de confusion et les mesures de précision du producteur et de l'utilisateur offrent des détails sur la performance pour chaque classe spécifique. Ensemble, ces métriques permettent une évaluation complète et approfondie des résultats de la classification, facilitant ainsi l'interprétation des données et la sélection du modèle le plus performant. Les cartes de classification obtenues sont comparées aux données de terrain ou aux ensembles de validation indépendants pour confirmer la précision des résultats. Cela permet de vérifier que les classifications reflètent fidèlement les conditions réelles sur le terrain.

1.6. Choix de la meilleure classification

1.6.1. Comparaison des performances

Les performances des différents algorithmes sont comparées en fonction des métriques d'évaluation. L'algorithme qui fournit les meilleures valeurs de précision, rappel, F-mesure, et autres métriques pertinentes est sélectionné comme le meilleur pour la classification.

1.6.2. Analyse des erreurs

Une analyse des erreurs est effectuée pour identifier les classes où les algorithmes présentent des faiblesses. Cette analyse aide à comprendre les limitations de chaque algorithme et à guider les ajustements nécessaires.

1.6.3. Sélection de l'Algorithme Optimal

L'algorithme offrant la meilleure performance globale, en tenant compte de la précision, de l'interprétabilité, et de la capacité à gérer des données complexes, est choisi pour la classification finale.

2. Résultats

2.1. Cartes d'Occupation du sol de Sine Kaloum issues de la classification par les algorithmes RF, SVM et CART

L'analyse des cartes d'occupation du sol, produites à partir des images Sentinel-2 et les algorithmes de machine learning RF, CART et SVM nous renseigne sur la répartition spatiale des catégories d'occupation du sol dans la région de Sine Kaloum en 2024. Les résultats cartographiques montrent que huit (08) classes d'unités d'occupation du sol (zone marécageuse, mangrove, végétation naturelle, habitat, terre salée, agriculture, eau, et sols nus) sont représentées dans des proportions différentes en fonction de l'algorithme choisie.

Les superficies des différentes classes d'occupation du sol, selon les algorithmes utilisés, sont présentées dans le tableau 2. La classe "Agriculture" domine dans la région de Sine Kaloum, avec des proportions de 73,88%, 65,61%, et 80,31% respectivement obtenues par les méthodes RF, CART et SVM. La classe "Habitat" maintient une proportion constante de 0,96% à travers toutes les classifications.

Les zones marécageuses sont quasiment absentes dans les résultats obtenus avec l'algorithme SVM, ne représentant que 0,07% de la superficie. Les sols nus, en revanche, sont particulièrement bien représentés dans la classification produite par l'algorithme CART, atteignant 14,36%. Les terres salées sont moins fréquentes dans la classification générée par SVM, avec une proportion de 0,29%. Les autres classes, telles que l'eau, la mangrove, et la végétation naturelle, affichent des proportions similaires dans les différentes classifications.

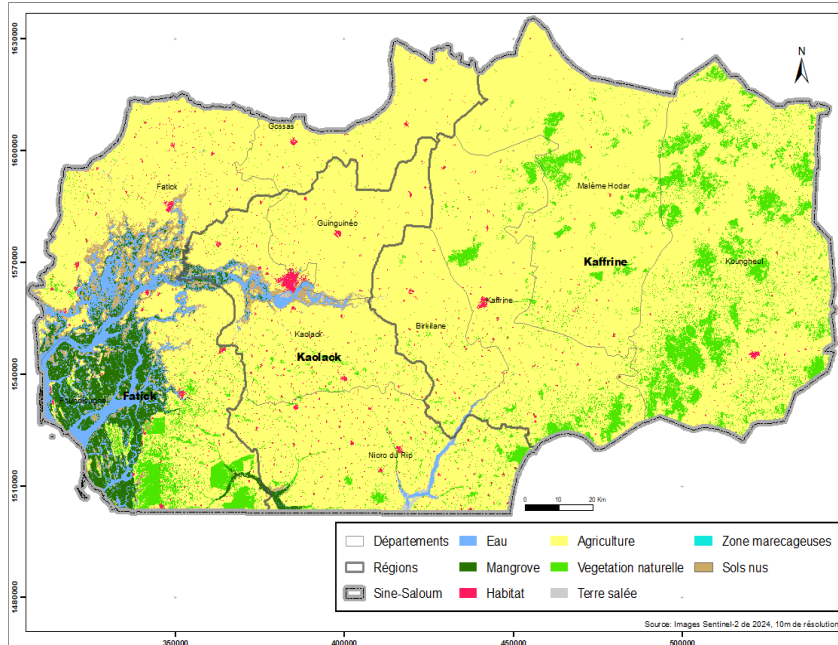
Tableau 2 : Superficies des classes d'occupation du sol de Sine Kaloum en 2024

CLASSES	SUPERFICIE (ha)			PROPORTION (%)		
	RF	CART	SVM	RF	CART	SVM
Eau	65533,598	65082,012	91535,06	2,78	2,76	3,88
Mangrove	81921,087	78888,717	82517,06	3,47	3,35	3,50
Habitat	22617,895	22617,895	22665,35	0,96	0,96	0,96
Agriculture	1741803,76	1546749,03	1893337,09	73,88	65,61	80,31
Végétation naturelle	206359,095	209559,262	204653,2	8,75	8,89	8,68
Terres salées	20274,983	21426,266	6772,43	0,86	0,91	0,29
Zones marécageuses	7523,437	72474,855	1565,884	0,32	3,07	0,07
Sols nus	211585,112	340820,928	54572,89	8,97	14,46	2,31
TOTAL	2357618,96	2357618,96	2357618,96	100	100	100

2.1.1. SVM

Les résultats révèlent que la classe "Agriculture" domine largement, couvrant 80,31% de la superficie totale, soit 1 893 337,09 hectares. Les autres classes se répartissent ainsi, p. la végétation naturelle occupe 8,68% (204 653,2 hectares), les plans d'eau 3,88% (91 535,06 hectares), les mangroves 3,50% (82 517,06 hectares), les sols nus 2,31% (54 572,89 hectares), les habitats 0,96% (22 665,35 hectares), les terres salées 0,29% (6 772,43 hectares) et les zones marécageuses 0,07% (1 565,88 hectares). La figure 3 illustre la répartition des classes d'occupation du sol dans la région de Sine Kaloum, obtenue à partir de l'algorithme SVM.

Figure 3 : Occupation du sol de 2024 de Sine Kaloum par l’algorithme de Machine Learning SVM

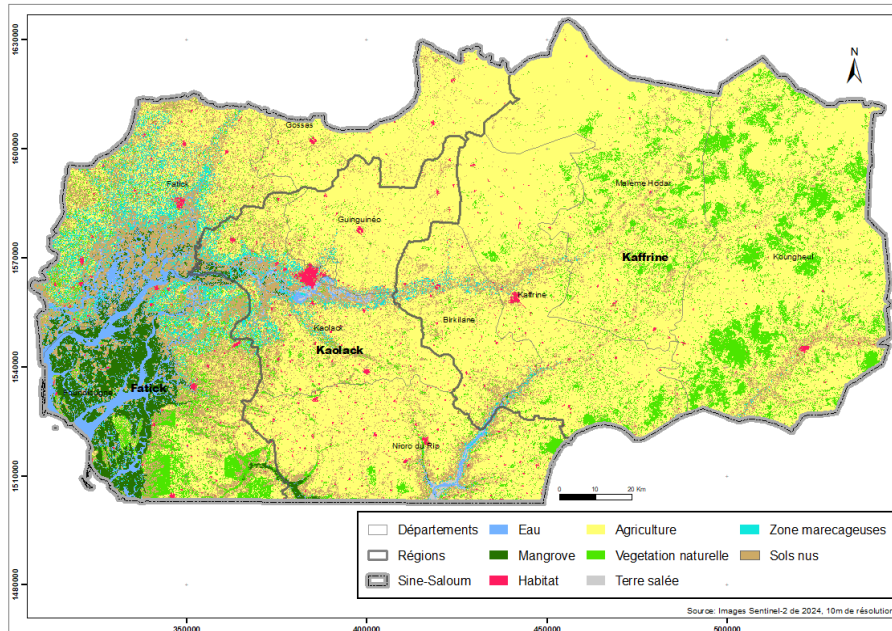


Il apparaît clairement que l’agriculture est l’activité principalement dans cette zone qui constitue le bassin arachidier du Sénégal. Cependant, avec la surexploitation des terres agricoles, la productivité a beaucoup régressé. Aussi, on enregistre une évolution dans les pratiques cultures. L’agriculture, culture commerciale, était dominante. Aujourd’hui, on note une diversification agriculture avec des cultures vivrières (mil, maïs).

2.1.2. CART

Ici, la classe "Agriculture" reste dominante mais dans une proportion moindre de 65,61% (soit 1 546 749,03 hectares). Notons une augmentation significative de la représentation des sols nus, atteignant 14,46% (340 820,93 hectares). La végétation naturelle couvre 8,89% (209 559,26 hectares), suivie des mangroves à 3,35% (78 888,72 hectares) et des zones marécageuses à 3,07% (72 474,86 hectares). Les plans d'eau, habitats et terres salées occupent respectivement 2,76% (65 082,01 hectares), 0,96% (22 617,90 hectares) et 0,91% (21 426,27 hectares). La figure 4 présente la répartition des classes d’occupation du sol obtenue avec l’algorithme CART.

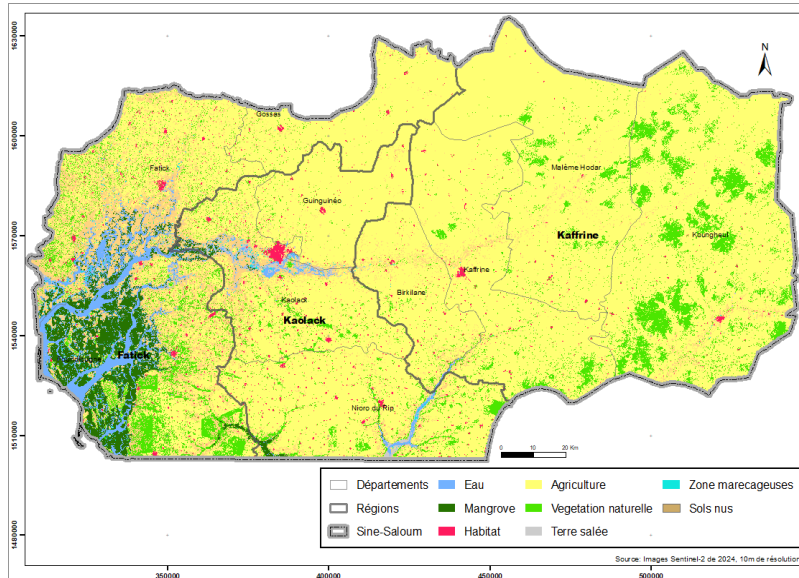
Figure 4 : Occupation du sol de 2024 de Sine Kaloum par l'algorithme de Machine Learning CART



2.1.3. RF

La figure 5 montre la répartition des classes d'occupation du sol issue de l'algorithme RF. La classe "Agriculture" y est prépondérante avec 73,88% (soit 1 741 803,76 hectares). Les sols nus suivent avec 8,97% (211 585,11 hectares), puis la végétation naturelle avec 8,75% (206 359,10 hectares). Les mangroves, les plans d'eau, les habitats, les terres salées et les zones marécageuses couvrent respectivement 3,47% (81 921,09 hectares), 2,78% (65 533,60 hectares), 0,96% (22 617,90 hectares), 0,86% (20 274,98 hectares) et 0,32% (7 523,44 hectares).

Figure 5 : Occupation du sol de 2024 de Sine Kaloum par l’algorithme de Machine Learning RF



2.2. Validation des cartes


Les résultats de la classification, sur la base des échantillons de validation, ont été soumis à une évaluation par l’analyse de la précision du producteur, la précision de l’utilisateur, la précision globale, le coefficient Kappa et la séparabilité des classes.

2.2.1. Résultats de la Mission terrain

L’évaluation de la précision des cartes d’occupation du sol a été effectuée en croisant les données issues de la télédétection et les observations terrain collectées à l’aide de KoboToolbox. Un total de 30 polygones géoréférencés a été échantillonné à travers les différentes classes d’occupation du sol, avec pour chaque classe des proportions différentes (Figure 6).

Les résultats obtenus montrent une concordance générale satisfaisante entre la classification automatique et les observations de terrain. Les photos collectées, permettent de mieux illustrer les classes observées sur le terrain.

Figure 6 : Répartition par classe, des échantillons terrains pour la validation de l'occupation du sol



2.2.2. Précision du producteur et de l'utilisateur

Les résultats de la classification ont été évalués à l'aide d'une analyse de la précision post-classification. Les valeurs de précision de l'utilisateur et du producteur pour les classifications obtenues avec les algorithmes SVM, RF, et CART ont été calculées et sont présentées dans le tableau 3.

Tableau 3 : Précision de l'utilisateur et du producteur de classification des images Sentinel 2A par les algorithmes de machine Learning SVM, RF et CART

Classe	Précision du producteur (%)			Précision de l'utilisateur (%)		
	F	CART	SVM	RF	CART	SVM
Eau	99,98	99,99	99,98	100	99,98	97,40
Mangrove	100	99,98	99,74	99,97	99,98	99,94
Habitat	100	100	100	100	100	100
Agriculture	99,78	99,49	97,94	99,46	99,46	97,53
Végétation naturelle	98,89	98,89	97,34	99,53	99,03	94,55
Terres salées	100	99,55	68,78	99,34	99,33	97,47
Zones marécageuses	89,55	91,04	86,57	100	93,85	77,33
Sols nus	88,18	86,21	22,17	91,33	85,78	88,24

Source : Données d'enquêtes

La précision du producteur pour l'ensemble des classes varie entre 86% et 100% pour les algorithmes RF et CART. En revanche, elle est nettement plus faible pour l'algorithme SVM, oscillant entre 22% et 69% pour les classes "terres salées" et "sols nus", tandis qu'elle reste élevée, entre 86% et 100%, pour les autres classes. Notamment, la précision du producteur atteint un niveau particulièrement bas de 22,17% pour la classe "sols nus" lorsque l'algorithme SVM est utilisé.

La précision de l'utilisateur suit un modèle similaire, avec des valeurs comprises entre 91% et 100% pour l'algorithme RF, et entre 85% et 100% pour l'algorithme CART. En revanche, cette précision est inférieure pour l'algorithme SVM, variant de 88% à 50% pour les classes "Plantations forestières (reboisement)", "forêt", "palmier à huile" et "aménagement agricole". La précision la plus faible observée pour l'utilisateur est de 77,33% pour la classe "zone marécageuse" avec l'algorithme SVM.

Bien que l'on note de légères différences entre la précision du producteur et celle de l'utilisateur, les pixels ont été correctement classifiés pour chacune des classes identifiées par les algorithmes CART, SVM, et RF (valeurs >85%), avec une précision modérée pour SVM.

Un examen approfondi des erreurs de classification (Tableau 4) a révélé des confusions notables dans certaines classes, manifestées par des erreurs d'omission et de commission. Les classes "eau", "mangrove", "habitat", "agriculture", et "végétation naturelle" sont parfaitement classifiées avec les trois algorithmes (erreurs d'omission et de commission <6%). Toutefois, des confusions importantes sont apparues entre les classes "terres salées", "zones marécageuses", et "sols nus" pour l'algorithme SVM.

Tableau 4 : Erreurs d'omission et de commission obtenues par les algorithmes de machine Learning SVM RF et CART

CLASSE	Erreur d'omission (%)			Erreur de commission (%)		
	RF	CART	SVM	RF	CART	SVM
Eau	0,02	0,01	0,02	0,00	0,02	2,60
Mangrove	0	0,02	0,26	0,03	0,02	0,06
Habitat	0	0,00	0,00	0,00	0,00	0,00
Agriculture	0,22	0,51	2,06	0,54	0,54	2,47
Végétation naturelle	1,11	1,11	2,66	0,47	0,97	5,45
Terres salées	0,00	0,45	31,22	0,66	0,67	2,53
Zones marécageuses	10,45	8,96	13,43	0,00	6,15	22,67
Sols nus	11,82	13,79	77,83	8,67	14,22	11,76

Les erreurs d'omission les plus importantes ont été observées pour l'algorithme SVM, avec des taux variants entre 31% et 77,83%, ce qui correspond à une précision du producteur allant de 69% à 22,17%. L'erreur d'omission la plus élevée a été observée dans la classe zone marécageuse avec une valeur de 22,67%, soit une précision de l'utilisateur estimée à 77,33%.

2.2.3. Précision globale et Kappa

Le Tableau 5 présente la précision globale obtenue pour les classifications réalisées avec les algorithmes de machine learning RF, CART, et SVM, laquelle correspond au

pourcentage de pixels correctement classifiés par rapport au total de pixels dans la matrice de confusion.

Les résultats montrent une précision globale exceptionnelle, avec des taux variants entre 97,56% et 99,70%. Il est important de souligner que l'algorithme RF a obtenu la précision la plus élevée, atteignant 99,70%, surpassant ainsi SVM (97,56%) et CART (99,59%).

Les valeurs de l'indice Kappa (K) sont également significatives, s'élevant à 0,96 pour SVM, 0,994 pour CART, et 0,996 pour RF. Ces valeurs, toutes supérieures à 0,81, indiquent une excellente évaluation et une forte concordance entre la carte d'occupation du sol dérivée des images Sentinel-2A et les données de validation. Elles reflètent un accord quasi parfait, démontrant ainsi l'efficacité des algorithmes de machine learning pour la classification des unités d'occupation du sol en milieu urbain.

Tableau 5 : Précision globale et Kappa des différentes classifications

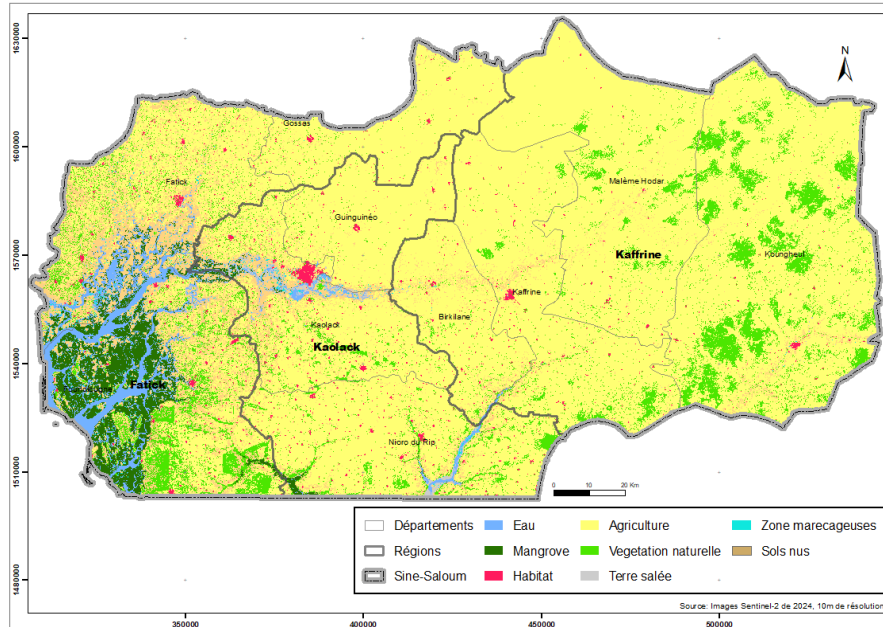
AML	KAPA	Précision globale (%)
RF	0,99595261	99,70
CART	0,99444181	99,59
SVM	0,96662459	97,56

Cette méthodologie de validation terrain, associée à l'analyse des erreurs de classification, montre l'importance d'un processus itératif dans l'évaluation de la cartographie par télédétection. Bien que les résultats soient globalement satisfaisants, des améliorations sont possibles grâce à l'intégration de nouvelles technologies et à une plus grande flexibilité dans la gestion des données multitemporelles.

2.3. Carte d'occupation du sol de Sine Kaloum de 2024

La Figure 7 présente la carte résultant de la classification de Sine Kaloum pour l'année 2024 à l'aide de l'algorithme de Machine Learning.

Figure 7 : Carte d'occupation du sol de Sine Kaloum de 2024



L'étude de la distribution des unités d'occupation du sol obtenues nous révèle que la surface de Sine Saloum est occupée à 66,001% par la végétation et à 33,99% de non-végétation (Milieu urbain, eau) (Tableau 6).

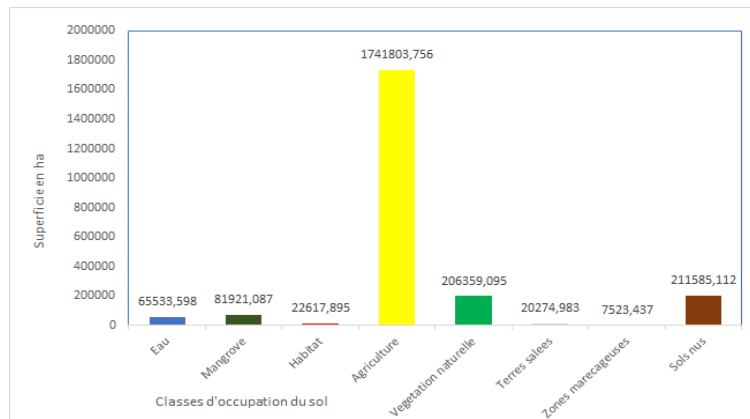
Tableau 6 : Distribution des classes d'occupation du sol du Sine Kaloum en 2024

Classes	Superficie (ha)	Proportion (%)
Eau	65533,6	2,78
Mangrove	81921,1	3,47
Habitat	22617,9	0,96
Agriculture	1741803,8	73,88
Végétation naturelle	206359,1	8,75
Terres salées	20274,9	0,86
Zones marécageuses	7523,4	0,32
Sols nus	211585,1	8,97
Total	2357618,9	100,00

La répartition des classes d'occupation du sol dans la région de Sine Kaloum (Figure 8) révèle une prédominance marquée de la classe "Agriculture", qui occupe 73,88% de la superficie totale, soit 1 741 803,76 hectares. En deuxième position, les sols nus couvrent

8,97% de la surface, équivalant à 211 585,11 hectares, suivis de près par la végétation naturelle, qui représente 8,75% de la superficie totale, soit 206 359,10 hectares. Les autres classes, incluant les mangroves, les plans d'eau, les habitats, les terres salées et les zones marécageuses, couvrent respectivement 3,47% (81 921,09 ha), 2,78% (65 533,60 ha), 0,96% (22 617,90 ha), 0,86% (20 274,98 ha) et 0,32% (7 523,44 ha) de la superficie totale.

Figure 8 : Distribution des unités d'occupation du sol dans le sine saloum en 2024



3. Discussion

Dans cette étude sur la classification des occupations du sol dans la région de Sine Kaloum, l'utilisation de Google Earth Engine (GEE) pour l'analyse des images Sentinel-2 s'avère particulièrement justifiée. GEE est une plateforme puissante qui permet un traitement à grande échelle des données géospatiales, offrant des capacités de calcul en cloud qui facilitent l'analyse de volumes massifs d'images sans nécessiter une infrastructure locale complexe. Selon N. Gorelick et al. (2017, p. 18-27), GEE a révolutionné l'accès et l'analyse des données de télédétection, rendant possible l'exécution d'analyses avancées de manière rapide et efficace, ce qui est essentiel pour notre étude.

L'application de techniques de machine learning, telles que RF, CART et SVM, offre des avantages indéniables en matière de précision et d'efficacité (M. A. C. NJEUGEUT et al., 2023, p. 310-32). Ces algorithmes permettent de capturer des relations complexes entre les variables d'entrée et les classes cibles, améliorant ainsi la performance des classifications par rapport aux méthodes traditionnelles reposant sur des seuils fixes ou des approches par règles (X. Liu et al., 2018, p. 227-39). Les images Sentinel-2 constituent un choix approprié en raison de leur résolution spatiale et temporelle élevée, ce qui est bénéfique pour la surveillance de l'occupation du sol. Avec leurs 13 bandes spectrales, ces images permettent une distinction fine entre les différentes classes d'occupation, comme le montre l'étude de M. Drusch et al. (2012, p. 25-36). Comparativement, d'autres sources de données, comme Landsat, peuvent être limitées par

une résolution inférieure et un intervalle de revisite moins fréquent (D. P. Roy et al., 2019, p. 111-254).

Les résultats de classification, obtenus à l'aide des algorithmes Random Forest (RF), CART et SVM, montrent des variations significatives en termes de précision et d'efficacité, avec une précision globale variant de 97,56 % à 99,70 %. RF affiche la meilleure performance à 99,70 %, en accord avec les travaux de M. A. C. NJEUGEUT et al. (2023, p. 310-32) et L. Breiman (2001, p. 5-32), qui ont également observé une performance élevée des algorithmes RF et CART pour des classifications similaires en télédétection.

Pendant, l'analyse des performances du SVM révèle des défis notables. Bien que ses résultats soient globalement acceptables, SVM se montre moins robuste, en particulier pour des classes complexes comme "sols nus", où la précision atteint seulement 22,17 %. Cette difficulté est corroborée par des études telles que celle de W. Zhang et al. (2019, p. 111-465), qui indiquent que les SVM peuvent rencontrer des problèmes de classification en raison de la variabilité spatiale des données. Des recherches menées en Afrique confirment également ces défis dans l'utilisation de SVM pour des classes d'occupation du sol ayant des caractéristiques spectrales similaires (M. A. C. Njeugeut et al., 2023, p. 310-32; M. A. Brovelli, Y. Sun, et V. Yordanov, 2020, p. 580).

Les valeurs de l'indice Kappa, supérieures à 0,81 pour tous les algorithmes, attestent d'une excellente concordance entre les cartes dérivées et les données de validation. Les valeurs élevées de Kappa sont indicatives d'une classification fiable (G. M. Foody, 2002, p. 185-201). Toutefois, nos résultats suggèrent qu'une optimisation des paramètres du SVM, pourrait améliorer sa valeur Kappa comme le notent plusieurs auteurs (M. A. C. Njeugeut et al., 2023, p. 310-32; P. Thanh Noi et M. Kappas, 2017, p. 18).

L'analyse de la précision du producteur et de l'utilisateur met en lumière les forces et faiblesses de chaque algorithme. RF et CART affichent des taux de précision utilisateur plus élevés, indiquant une meilleure gestion de la diversité des classes, comme observé au Sénégal (B. Solly, E. H. B. Dieye, et O. Sy, 2020, p. 35-49). En revanche, SVM présente des disparités significatives, notamment en ce qui concerne certaines classes, avec des confusions notables entre "terres salées", "zones marécageuses" et "sols nus". Plusieurs travaux suggèrent que l'amélioration de la qualité des données d'entrée ou l'application de techniques de prétraitement pourraient atténuer ces erreurs (D. Lu et Q. Weng, 2007, p. 823-70).

En somme, cette étude enrichit la littérature sur la classification de l'occupation du sol en Afrique en fournissant des comparaisons directes entre plusieurs algorithmes de machine learning et en mettant en lumière les défis spécifiques liés à l'application de SVM. Les résultats encouragent également des recherches futures sur l'optimisation des algorithmes et l'amélioration de la qualité des données d'entrée pour des classifications plus précises et fiables. L'utilisation de Google Earth Engine, associée à des techniques de machine

learning et aux images Sentinel-2, constitue une approche robuste et efficace pour la classification de l'occupation du sol, ouvrant la voie à des études futures sur l'optimisation des processus analytiques dans des contextes géographiques variés.

Conclusion

Cette étude a évalué la performance de trois algorithmes de classification de machine learning Random Forest (RF), Classification and Regression Trees (CART), et Support Vector Machines (SVM) pour cartographier l'occupation du sol dans la région de Sine Kaloum à partir d'images Sentinel-2A. Les résultats montrent que les algorithmes RF et CART offrent des performances globalement supérieures par rapport à SVM, avec des précisions globales atteignant respectivement 99,70% et 99,59%, tandis que SVM obtient une précision légèrement inférieure de 97,56%. Ces performances élevées, mesurées par les indices Kappa supérieurs à 0,81, témoignent d'une excellente concordance entre les cartes d'occupation du sol générées et les données de validation.

La précision du producteur et de l'utilisateur varie selon les algorithmes, les meilleurs résultats étant obtenus avec RF et CART. En revanche, SVM présente des défis particuliers, notamment une faible précision pour les classes "sols nus" et des erreurs de commission plus fréquentes pour certaines catégories. Les erreurs de classification, surtout pour les classes de terres salées et de zones marécageuses, mettent en évidence les limites de SVM dans la gestion de classes avec des caractéristiques spectrales similaires.

Les résultats indiquent que, bien que tous les algorithmes étudiés fournissent une classification fiable et précise, RF et CART se distinguent par leur robustesse et leur précision globale. Ces algorithmes sont donc recommandés pour les applications de cartographie de l'occupation du sol dans des contextes similaires. Néanmoins, l'intégration de techniques de prétraitement des données ou l'optimisation des paramètres de SVM pourraient améliorer ses performances dans des classifications complexes.

Cette recherche démontre l'efficacité des techniques de machine learning pour la classification des données de télédétection et fournit des recommandations pour les choix d'algorithmes en fonction des caractéristiques spécifiques des classes d'occupation du sol. Les futures études pourraient explorer des approches combinées ou hybrides pour améliorer encore la précision et la robustesse des classifications dans des environnements variés.

En conclusion, cette étude souligne l'efficacité des algorithmes RF et CART pour la classification de l'occupation du sol à Sine Kaloum, tandis que SVM nécessite des ajustements spécifiques pour optimiser sa performance. Des recherches futures devraient se concentrer sur l'amélioration des techniques de classification, en particulier pour les classes où des confusions sont fréquentes.

Références bibliographiques

- ALONGI Daniel, 2008, Mangrove forests, p. Resilience, protection from tsunamis, and responses to global climate change. *Estuarine, Coastal and Shelf Science* 76 (1), p. 1-13.
- BELGIU Mariana, et Lucian Drăguț, 2016, Random Forest in Remote Sensing, p. A Review of Applications and Future Directions. *ISPRS Journal of Photogrammetry and Remote Sensing* 114 (avril), p.24-31.
- BETHEMONT Jacques, 2000, Cormier-Salem, Marie-Christine, éd. (1999) Rivières du Sud. Sociétés et mangroves ouest-africains. Paris, IRD, 2 vol., 416 et 288 p. (ISBN 2-7099-1425-5). *Cahiers de géographie du Québec* 44 (121), p. 95.
- BREIMAN Leo, 2001, Random Forests. *Machine Learning* 45 (1), p. 5-32.
- BREIMAN Leo, Friedman, Stone, et Olshen, éd., 1998, *Classification and Regression Trees*. 1. CRC Press repr. Boca Raton, Fla., p. Chapman & Hall/CRC.
- BROVELLI Maria Antonia, Yaru Sun, et Vasil Yordanov, 2020, Monitoring Forest Change in the Amazon Using Multi-Temporal Remote Sensing Data and Machine Learning Classification on Google Earth Engine. *ISPRS International Journal of Geo-Information* 9 (10), p. 580.
- BURGES Christopher, 1998, A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery* 2 (2), p. 121-67.
- DRUSCH, Del Bello, Carlier, Colin, Fernandez, Gascon, Hoersch, et al., 2012, Sentinel-2, p. ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing of Environment, The Sentinel Missions - New Opportunities for Science*, 120 (mai), p.25-36.
- FOODY Giles, 2002, Status of Land Cover Classification Accuracy Assessment. *Remote Sensing of Environment* 80 (1), p. 185-201.
- GORELICK Noel, Matt Hancher, Mike Dixon, Simon Ilyushchenko, David Thau, et Rebecca Moore, 2017, Google Earth Engine, p. Planetary-Scale Geospatial Analysis for Everyone. *Remote Sensing of Environment, Big Remotely Sensed Data*, p. tools, applications and experiences, 202 (décembre), p.18-27.
- HUETE, 1988, A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment* 25 (3), p. 295-309.
- LAMBIN Eric, Helmut Geist, et Erika Lepers, 2003, Dynamics of Land-Use and Land-Cover Change in Tropical Regions. *Annual Review of Environment and Resources* 28 (Volume 28, 2003), p. 205-41.

- LI Miao, Shuying Zang, Bing Zhang, Shanshan Li, et Changshan Wu, 2014, A Review of Remote Sensing Image Classification Techniques, p. The Role of Spatio-Contextual Information. *European Journal of Remote Sensing* 47 (1), p. 389-411.
- LIU Xiaoping, Guohua Hu, Yimin Chen, Xia Li, Xiaocong Xu, Shaoying Li, Fengsong Pei, et Shaojian Wang, 2018, High-Resolution Multi-Temporal Mapping of Global Urban Land Using Landsat Images Based on the Google Earth Engine Platform. *Remote Sensing of Environment* 209 (mai), p. 227-39.
- LOH Wei-Yin, 2011, Classification and Regression Trees. *WIREs Data Mining and Knowledge Discovery* 1 (1), p. 14-23.
- LU et Weng, 2007, A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing* 28 (5), p. 823-70.
- MOREAU Noële, 1991, Contribution de la télédétection à l'étude de l'évolution des paysages de mangroves de l'Afrique de l'Ouest. These de doctorat, Bordeaux 3.
- MOUNTRAKIS Giorgos, Jungho Im, et Caesar Ogole, 2011, Support Vector Machines in Remote Sensing, p. A Review. *ISPRS Journal of Photogrammetry and Remote Sensing* 66 (3), p. 247-59.
- NJEUGEUT MBIAFEU Amandine Carine, Marc Youan Ta, KAMENAN Satti Jean-Robert, KOUAME Kouadio Armel, ASSOMA Tchimou Vincent, et JOURDA Jean Patrice, 2023, Mapping of land use units in the District of Abidjan using Google Earth Engine cloud, based on Sentinel-2 optical images and Machine Learning algorithms. *International Journal of Innovation and Applied Studies* 40 (1), p. 310-32.
- PETTORELLI Nathalie, William F. Laurance, Timothy G. O'Brien, Martin Wegmann, Harini Nagendra, et Woody Turner, 2014, Satellite Remote Sensing for Applied Ecologists, p. Opportunities and Challenges. Édité par E.J. Milner-Gulland. *Journal of Applied Ecology* 51 (4), p. 839-48.
- POWELL Scott, Dirk Pflugmacher, Alan Kirschbaum, Yunsuk Kim, et Warren Cohen, 2007, Moderate Resolution Remote Sensing Alternatives, p. A Review of Landsat-like Sensors and Their Applications. *Journal of Applied Remote Sensing. Vol. 1. 16 p. 1.*
- RODRIGUEZ Galiano, Ghimire, Rogan, Chica-Olmo, et Rigol-Sanchez, 2012, An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing* 67 (janvier), p.93-104.
- ROY David, Haiyan Huang, Luigi Boschetti, Louis Giglio, Lin Yan, Hankui H. Zhang, et Zhongbin Li, 2019, Landsat-8 and Sentinel-2 burned area mapping - A combined sensor multi-temporal change detection approach. *Remote Sensing of Environment* 231 (septembre), p.111254.

SAVANE Issiaka, Kapo Martin Coulibaly, et Pierre Gioan, 2001, Variabilité climatique et ressources en eau souterraines de tarissement des cours d'eau. *Sècheresse* 14 (1), p. 37-42.

SOLLY Boubacar, El Hadji Balla Dieye, et Oumar Sy, 2020, Remote Sensing Mapping of Land Use and Land Cover Changes in Upper Casamance, Senegal, 1987-2018. *American Journal of Remote Sensing* 8 (2), p. 35-49.

THANH Noi, Phan, et Martin Kappas, 2017, Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. *Sensors* 18 (2), p. 18.

ZHANG Wenmin, Martin Brandt, Qiao Wang, Alexander V. Prishchepov, Compton J. Tucker, Yunmei Li, Heng Lyu, et Rasmus Fensholt, 2019, From Woody Cover to Woody Canopies, p. How Sentinel-1 and Sentinel-2 Data Advance the Mapping of Woody Plants in Savannas. *Remote Sensing of Environment* 234 (décembre), p.111-465.