



**HAL**  
open science

# Téledétection des forêts dégradées en Guinée à partir des données Sentinel-2

An Vo Quang Truong

► **To cite this version:**

An Vo Quang Truong. Téledétection des forêts dégradées en Guinée à partir des données Sentinel-2. Géographie. Université Paris Cité, 2022. Français. NNT : 2022UNIP7267 . tel-04448494

**HAL Id: tel-04448494**

**<https://theses.hal.science/tel-04448494>**

Submitted on 9 Feb 2024

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Thèse de doctorat  
Présentée par An VO QUANG TRUONG

# Téledétection des forêts dégradées en Guinée à partir des données Sentinel-2

IGN FI  
UMR 8586 PRODIG (Paris 1/Paris 7/Paris 4/IRD/AgroParisTech)  
UMR 8236 LIED (Laboratoire Interdisciplinaire des Energies de Demain)  
Ecole doctorale 624 : Sciences des Sociétés  
Spécialité doctorale : Géomatique

Soutenue le 13 décembre 2022  
Etablissement de soutenance : Université Paris Cité

## Jury

|                     |              |                                      |
|---------------------|--------------|--------------------------------------|
| Catherine Ottlé     | Rapportrice  | Directrice de Recherche, CNRS - UVSQ |
| Agnès Bégué         | Rapportrice  | Directrice de Recherche, CIRAD       |
| Valéry Gond         | Examineur    | HDR, CIRAD                           |
| Inge Jonckheere     | Examinatrice | PhD, FAO                             |
| Averti Suspense Ifo | Examineur    | PhD, Université Marien N'GOUABI      |
| Stéphane Jacquemoud | Examineur    | Professeur, IPGP                     |

## Encadrement de la thèse

|                  |                       |                                   |
|------------------|-----------------------|-----------------------------------|
| Nicolas Delbart  | Directeur             | Professeur, Université Paris Cité |
| Gabriel Jaffrain | Membre invité du jury | IGN FI                            |
| Camille Pinet    | Membre invité du jury | IGN FI                            |



Cette thèse a été réalisée dans un contexte de contrat de thèse CIFRE (n° 2018/0129) entre :

Le Pôle de recherche pour l'organisation et la diffusion de l'information géographique (PRODIG)  
Campus Condorcet  
5, cours des Humanités – 93300 Aubervilliers  
France

puis

le Laboratoire Interdisciplinaire des Energies de Demain (LIED)  
Université Paris 7 – Paris Diderot  
8 place Paul-Ricoeur – 75013 Paris  
France

et

la société IGN FI  
7 rue Biscornet  
75012 Paris  
France

#### *Préambule*

*Le contexte sanitaire durant l'épidémie de Covid-19 ayant empêché la conduite des travaux prévus, et en particulier la réalisation d'une campagne de terrain en République du Congo, le plan de travail a dû être adapté en montant un projet de sciences participatives pour me former auprès d'experts analystes de données, ce qui a abouti à la mise en place d'une méthode basée sur l'apprentissage profond. Cette étude est l'objet du chapitre 4.*



## Résumé

La dégradation forestière englobe tout ce qui peut abîmer et fragiliser la forêt : coupes sélectives pour les bois rares, incendies, sécheresse, etc. La dégradation des forêts est subtile et moins visible que la déforestation. Pourtant, les forêts dégradées sont, à terme, vouées à disparaître. En outre, la dégradation des forêts est une préoccupation majeure, car le potentiel de séquestration du carbone est alors réduit. C'est un biais important dans les bilans carbone des pays qui ne tiennent généralement pas compte de la dégradation forestière.

Le présent travail de thèse vise à évaluer le potentiel des images satellites Sentinel-2, de l'Agence Spatiale Européenne, pour la détection des forêts dégradées en Guinée, Afrique de l'Ouest. Outre la fragmentation des forêts causée par le changement d'utilisation des terres, le principal processus de dégradation observé y est la coupe sélective, en particulier dans le massif de Ziama, pourtant classé comme réserve de biosphère par l'UNESCO.

Généralement, l'identification des forêts dégradées par satellite nécessite des coûts importants en termes de main d'œuvre et d'expertise de photo-interprétation, car la délimitation des forêts dégradées est manuelle. La première partie de la thèse est consacrée à l'amélioration de la méthode de photo-interprétation des forêts dégradées. Nos résultats témoignent de l'apport majeur de Sentinel-2 grâce à sa large gamme de réflectances qui couvre le moyen infrarouge et qui a montré une considérable amélioration de la séparabilité de la forêt dense et de la forêt dégradée. Ensuite, grâce à sa résolution temporelle qui permet de valider l'état de dégradation forestière.

Les valeurs radiométriques d'images Sentinel-2 acquises de 2015 à 2020 ont été analysées au regard d'observations au sol réalisées avec un forestier local lors d'une campagne terrain en Guinée en 2019. Nos résultats montrent que les indices liés à l'humidité (teneur en eau de la canopée [CWC], indice de stress hydrique [MSI]), associés à l'indice de surface foliaire (LAI) extrait des données Sentinel-2, sont fortement liés au degré de dégradation.

En utilisant les séries temporelles des mesures LAI, MSI et CWC comme données d'entrée, une méthode de classification 'Random forest' a été développée, différant des méthodes existantes par l'inclusion des valeurs des pixels voisins dans l'algorithme afin d'imiter la reconnaissance visuelle de forêts dégradées par un opérateur humain. L'inclusion du contexte montre de meilleurs scores de précision et les résultats de cartographie ont été validés par les observations de terrain. La photo-interprétation de seulement 1,6 % de la surface d'une image pour l'entraînement du modèle a permis d'atteindre une précision globale de 89,6 %, ce qui correspond à une nette avancée par rapport aux méthodes existantes.

Enfin, une autre méthode contextuelle a été explorée grâce à des techniques d'apprentissage profond. Il s'agissait d'évaluer si les réseaux neuronaux convolutifs (CNN) peuvent tout autant améliorer la détection des forêts dégradées et supprimer le besoin de réentraînement. Nous avons identifié le manque de données labellisées comme obstacle majeur pour l'entraînement des modèles CNN et élargi les données d'entraînement en photo-interprétant une série d'images entre 2015 et 2020. Nous avons comparé 3 modèles CNN et évalué leur performance pour la détection des forêts dégradées. Le résultat de l'étude est la création d'un modèle qui atteint 94% de précision.

Cette méthode est transférable et peut s'appliquer d'une année à une autre et d'un massif guinéen à un autre. Validée de façon indépendante par des experts en occupation du sol, la méthode ne requiert ainsi

pas de photo-interprétation de nouvelles images en 2021. Cette thèse présente une base solide pour les opérateurs responsables de la production des cartographies nationales et une production de cartes plus rapide et moins coûteuse à partir d'images satellites gratuites et accessibles à tous.

**Mots-clés** : télédétection, optique, classification, cartographie, Sentinel-2, série temporelle, couvert forestier, dégradation forestière, déforestation, forêt tropicale, REDD, détection de changement, CNN, apprentissage profond

## Abstract

Forest degradation includes everything that can damage and weaken the forest: selective logging for rare wood, fires, drought, etc. Forest degradation is subtle and less visible than deforestation. However, degraded forests are doomed to disappear. Moreover, forest degradation is a major concern because the potential for carbon sequestration is reduced. This is an important bias in the carbon balances of countries that generally do not take into account forest degradation. This thesis aims to evaluate the potential of Sentinel-2 satellite images, from the European Space Agency, for the detection of degraded forests in Guinea, West Africa. In addition to forest fragmentation caused by land use change, the main degradation process observed is selective logging, particularly in the Ziama Massif, which is classified as a biosphere reserve by UNESCO. Generally, the identification of degraded forests by satellite requires significant costs in terms of manpower and photo-interpretation expertise, as the delineation of degraded forests is manual. The first part of the thesis is devoted to the improvement of the photo-interpretation method of degraded forests. Our results show the major contribution of Sentinel-2 due to its wide range of reflectances which covers the short-wave infrared and which showed a considerable improvement of the separability of the dense forest and the degraded forest. Secondly, due to its temporal resolution which allows to validate the state of forest degradation. The radiometric values of Sentinel-2 images acquired from 2015 to 2020 were analyzed against ground observations made with a local forester during a field campaign in Guinea in 2019. Our results show that moisture-related indices (canopy water content [CWC], water stress index [MSI]), combined with the leaf area index (LAI) extracted from Sentinel-2 data, are strongly related to the degree of degradation. Using the time series of LAI, MSI and CWC measurements as input data, a 'Random forest' classification method was developed, differing from existing methods by including neighboring pixel values in the algorithm to mimic the visual recognition of degraded forests by a human operator. The inclusion of context shows better accuracy scores, and the mapping results were validated by field observations. Photo-interpretation of only 1.6% of an image area for model training resulted in an overall accuracy of 89.6%, which is a clear advance over existing methods. Finally, another contextual method was explored using deep learning techniques. This was to evaluate whether convolutional neural networks (CNNs) can equally improve detection of degraded forests and remove the need for retraining. We identified the lack of labeled data as a major barrier to training CNN models and expanded the training data by photo-interpreting a series of images between 2015 and 2020. We compared 3 CNN models and evaluated their performance in detecting degraded forests. The result of the study is the creation of a model that achieves 94% accuracy. This method is transferable and can be applied from one year to another and from one Guinean massif to another. Independently validated by land use/land cover experts, the method does not require photo-interpretation of new images in 2021. This thesis presents a solid basis for operators responsible for the production of national land use/land cover maps and a faster and less expensive production of maps from satellite images that are free and accessible to all.

**Keywords:** remote sensing, optical, classification, mapping, Sentinel-2, time series, forest cover, forest degradation, deforestation, tropical forest, REDD, change detection, CNN, deep learning





## Remerciements

Je remercie chaleureusement toutes les personnes qui m'ont aidée pendant l'élaboration de ma thèse et particulièrement mon directeur de thèse Nicolas Delbart, pour sa patience et son soutien, sa grande disponibilité et ses nombreux conseils durant la rédaction de ma thèse.

Ce travail n'aurait pas été possible sans le soutien d'IGN FI, qui m'ont permis de me consacrer sereinement à l'élaboration de ma thèse. Je remercie Christophe Dekeyne et Aurélie Milledrogues, directeur général et directrice générale adjointe en charge de la technique à IGN FI, pour leur soutien tout au long de cette thèse. Camille Pinet a énormément contribué à ce que ma thèse se déroule dans d'excellentes conditions, je la remercie pour son soutien.

Mes remerciements s'adressent également à toute l'équipe IGN FI en France ou en mission. Je tiens à exprimer toute ma gratitude envers (dans le désordre) : Gaby, Adrien, Arthur, Yvan, Mathilde M, Nicolas, Greg, Laurent H, Vincent, Alain, Didier, Jean-Abdou, Sébastien, Axel, Véro, Wafa, Elisabeth, Julie, Fabienne, Chloé, Rudy, Nathalie, Aurélie, Irina, Stéphane P, Aude, Christophe G, Gaëtan, Laurent F, Mathilde D, Valentin, et tous les autres.

Ce travail n'aurait pu être mené à bien sans la disponibilité et l'accueil chaleureux que m'ont témoigné Mory, Sékou, Frédéric, Maxime et Arthur Leroux, pour ma campagne de terrain en 2019. Je les remercie pour leur grande gentillesse et attention lors de mon séjour en Guinée.

Je désire en outre vivement remercier Amadou Conté, Amara Kourouma, Yvon Aubriot et M'Ballou Sylla pour leur temps et leur précieuse aide dans la validation externe des cartographies issues du travail de thèse.

Je remercie ensuite l'ensemble des membres du jury, qui m'ont fait l'honneur de bien vouloir étudier avec attention mon travail : Catherine Ottlé et Agnès Bégué pour avoir accepté d'être rapportrices de cette thèse ; Valéry Gond, Inge Jonckheere, Stéphane Jacquemoud et Suspense Averti Ifo pour avoir accepté d'examiner cette thèse.

Au terme de ce parcours, je suis redevable à Camille, Gaby, Valentina et Dan qui ont relu mon manuscrit pour achever cette thèse. Leurs attentions et encouragements m'ont accompagnée tout au long de ces derniers mois. Je remercie mes parents et mon frère pour leur soutien moral.

Enfin, j'ai une pensée toute particulière pour mes chers collègues Gabriel Jaffrain et Adrien Moiret, qui ont été mes mentors et amis depuis le début de la thèse. Leur soutien indéfectible m'a portée pendant ces 4 années et je n'aurai pas achevé ce travail sans leur guidance, leur bienveillance et les fous rires quotidiens. C'est un privilège de travailler à leurs côtés. Merci d'être mon plus grand soutien.



## Liste des acronymes

|               |   |
|---------------|---|
| <b>AFD</b>    | Agence Française du Développement   |
| <b>AGB</b>    | Biomasse aérienne   |
| <b>BFAST</b>  | Breaks For Additive Seasonal and Trend  |
| <b>CCNUCC</b> | Convention-Cadre des Nations Unies sur les Changements Climatiques  |
| <b>CIFRE</b>  | Conventions Industrielles de Formation par la REcherche   |
| <b>CILSS</b>  | Comité Inter-états de Lutte contre la Sécheresse dans le Sahel  |
| <b>CIRAD</b>  | Centre de coopération internationale en recherche agronomique pour le développement   |
| <b>CNES</b>   | Centre National d'Etudes Spatiales  |
| <b>CNN</b>    | Convolutional Neural Networks (réseaux neuronaux convolutifs)   |
| <b>CODED</b>  | Détection de dégradation continue   |
| <b>CORINE</b> | Coordination des Informations sur l'environnement   |
| <b>CWC</b>    | Canopy Water content  |
| <b>DL</b>     | Deep learning   |
| <b>EC</b>     | Erreur de commission  |
| <b>ECV</b>    | Variable climatique essentielle   |
| <b>EO</b>     | Erreur d'omission   |
| <b>ESA</b>    | Agence Spatiale Européenne  |
| <b>ETM+</b>   | Enhanced Thematic Mapper Plus   |
| <b>EVI</b>    | Enhanced Vegetation Index   |
| <b>FAO</b>    | Food and Agriculture Organization of the United Nations (Organisation des Nations unies pour l'alimentation et l'agriculture) |
| <b>FOTO</b>   | FOurier-based Textural Ordination   |
| <b>GEDI</b>   | Global Ecosystem Dynamics Investigation   |
| <b>GES</b>    | Gaz à effet de serre  |
| <b>GFW</b>    | Global Forest Watch   |
| <b>GPU</b>    | Graphics Processing Unit (processeur graphique)   |
| <b>IPCC</b>   | Groupe d'experts intergouvernemental sur l'évolution du climat  |
| <b>ISS</b>    | Station spatiale internationale   |
| <b>LAI</b>    | Leaf Area Index   |
| <b>LiDAR</b>  | Light detection and ranging   |
| <b>LIED</b>   | Laboratoire interdisciplinaire de recherche en énergie  |
| <b>LMM</b>    | Modèle de mélange linéaire  |
| <b>LULC</b>   | Land Cover Land Use   |
| <b>MIR</b>    | Moyen infrarouge  |
| <b>MSI</b>    | Moisture Stress Index   |
| <b>NDFI</b>   | Normalized Difference Fraction Index  |
| <b>NDVI</b>   | Indice de végétation par différence normalisée  |
| <b>NPV</b>    | Végétation non-photosynthétique (non-photosynthetic vegetation)   |
| <b>OA</b>     | Overall Accuracy  |
| <b>OCS</b>    | Occupation du Sol   |
| <b>OIBT</b>   | Organisation Internationale pour les bois tropicaux   |
| <b>OTB</b>    | Orfeo ToolBox   |
| <b>PA</b>     | Producer accuracy (précision producteur)  |

|               |   |
|---------------|---|
| <b>PAI</b>    | Plant Area Index (indice de surface végétale)                             |
| <b>PALSAR</b> | Phased Array L-band Synthetic Aperture Radar                              |
| <b>PFBC</b>   | Partenariat sur les forêts du bassin du Congo                             |
| <b>PIR</b>    | Proche infrarouge   |
| <b>PVI</b>    | Indice de végétation perpendiculaire                                      |
| <b>R</b>      | Rouge   |
| <b>Radar</b>  | RAdio Detection And Ranging   |
| <b>REDD+</b>  | Reducing emissions from deforestation and forest degradation              |
| <b>RF</b>     | Random Forest   |
| <b>RMSE</b>   | Erreur quadratique moyenne  |
| <b>ROI</b>    | Regions Of Interest (régions d'intérêt)                                   |
| <b>RSO</b>    | Radars à Synthèse d'Ouverture   |
| <b>S2</b>     | Sentinel-2  |
| <b>SAR</b>    | Synthetic Aperture Radar  |
| <b>SAVI</b>   | Indice de végétation ajusté au sol  |
| <b>SIG</b>    | Système d'Information Géographique  |
| <b>SIWSI</b>  | Short-wave Infrared Water Stress Index                                    |
| <b>SMA</b>    | Spectral Mixture Analysis (analyse par démixage spectral)                 |
| <b>SMOC</b>   | Système mondial d'observation du climat                                   |
| <b>SNAP</b>   | Sentinel Application Platform   |
| <b>SR</b>     | Simple ratio  |
| <b>SVM</b>    | Support Vector Machine  |
| <b>UA</b>     | User accuracy (précision utilisateur)                                     |
| <b>UICN</b>   | Union internationale pour la conservation de la nature                    |
| <b>UNESCO</b> | Organisation des Nations unies pour l'éducation, la science et la culture |
| <b>USGS</b>   | Institut d'études géologiques des États-Unis                              |
| <b>VCS</b>    | Verified Carbon Standard  |
| <b>VNP</b>    | Végétation non-photosynthétique   |
| <b>VP</b>     | Végétation photosynthétique   |
| <b>WRI</b>    | World Resources Institute   |
| <b>WWF</b>    | World Wide Fund for Nature (Fonds mondial pour la nature)                 |
| <b>ZAEG</b>   | Zonage Agroécologique de Guinée   |
| <b>ZICO</b>   | Zone d'importance pour la conservation des oiseaux                        |

## Table des matières

|   |    |
|---|----|
| Téledétection des forêts dégradées en Guinée à partir des données Sentinel-2.....                                     | 1  |
| Résumé.....   | 5  |
| Abstract.....   | 7  |
| Remerciements.....  | 9  |
| Liste des acronymes.....  | 11 |
| Table des matières.....   | 13 |
| Chapitre 1.....   | 15 |
| Introduction et problématique.....  | 15 |
| 1.1 Importance des forêts tropicales.....   | 15 |
| 1.2. La téledétection pour le suivi de la déforestation en milieu tropical.....                                       | 19 |
| 1.3. La difficulté de cartographier des changements plus subtils du couvert forestier.....                            | 22 |
| 1.4. Problématique et hypothèses de travail.....  | 24 |
| 1.5 Choix d'utilisation d'outils libres.....  | 27 |
| 1.6. Organisation du manuscrit.....   | 28 |
| Chapitre 2.....   | 29 |
| Détection des forêts dégradées par photo-interprétation en Guinée : amélioration de la méthode.....                   | 29 |
| 2.1. Site d'étude : la Guinée forestière.....   | 29 |
| 2.2. Etat des lieux : le projet Zonage Agro-Écologique de Guinée (ZAEG).....  | 33 |
| 2.3. Définition des systèmes arborés dans le projet ZAEG.....   | 35 |
| 2.4. Données de terrain collectées durant la thèse.....   | 38 |
| 2.5. Amélioration de l'interprétation visuelle des forêts dégradées et création d'un jeu de données de référence..... | 50 |
| 2.6. Conclusion sur la photo-interprétation des forêts dégradées.....   | 59 |
| Chapitre 3.....   | 61 |
| Détection semi-automatique des forêts dégradées.....  | 61 |
| 3.1. Etat de l'art.....   | 61 |
| 3.2. Evaluation des méthodes SMA pour la détection des forêts dégradées dans le contexte guinéen.....                 | 67 |
| 3.3. Analyse des variations temporelles des indices spectraux.....  | 78 |
| 3.4. Utilisation des indices biophysiques pour la détection des forêts dégradées.....                                 | 80 |
| 3.5. Détection des forêts dégradées à partir des variables biophysiques au niveau du pixel et de son voisinage.....   | 82 |
| 3.6. Conclusion sur l'utilisation des séries temporelles optiques dans la détection des forêts dégradées.....         | 94 |

|   |     |
|---|-----|
| Chapitre 4.....   | 97  |
| Détection des forêts dégradées à partir des sciences participatives et de l'apprentissage profond ..... | 97  |
| 4.1. Introduction.....  | 97  |
| 4.2. Etat de l'art : applications des réseaux de neurones en télédétection .....                        | 99  |
| 4.3. Matériels et méthodes .....  | 101 |
| 4.4. Résultats.....   | 117 |
| 4.5. Conclusion sur la détection des forêts dégradées avec le deep learning .....                       | 123 |
| Chapitre 5.....   | 125 |
| Conclusion et perspectives .....  | 125 |
| 5.1. Synthèse des résultats sur la détection des forêts dégradées .....                                 | 125 |
| 5.2. Perspectives .....   | 135 |
| Bibliographie .....   | 139 |
| Annexes .....   | 153 |
| A.1. Publications pendant la thèse .....  | 153 |
| A.2. Syllabus des formations données pendant la thèse.....  | 154 |
| A.3. Matrices d'erreur brute issue du modèle U-Net (chapitre 4) .....                                   | 155 |
| A.4 Table des illustrations .....   | 156 |

# Chapitre 1

## Introduction et problématique

### 1.1 Importance des forêts tropicales

Les forêts tropicales forment le plus grand biome forestier mondial par leur superficie (45%), devant les forêts boréales (27%) et tempérées (16%) (FAO, 2020). Elles constituent ainsi des épicycles mondiaux de la biodiversité terrestre et jouent un rôle crucial dans le cycle du carbone global et dans les cycles hydrologique et biochimique. Les forêts tropicales couvrent 7 à 10% de la surface terrestre, stockent 40 à 50% de l'ensemble du carbone de la végétation terrestre et traitent annuellement environ six fois plus de carbone via la photosynthèse et la respiration que les humains émettent lors de l'utilisation de combustibles fossiles (Lewis, 2006; Lewis et al., 2009; Malhi and Grace, 2000). A ces flux de carbone s'ajoutent celui lié aux changements d'occupation du sol. Ainsi, le GIEC (Groupe d'Experts intergouvernemental sur l'Evolution du Climat) estime que 1,7 milliard de tonnes de CO<sub>2</sub> sont rejetées chaque année dans l'atmosphère dû aux changements du couvert terrestre, et en grande partie à la déforestation tropicale. La déforestation tropicale, principalement liée à la pression anthropique, modifie les cycles biogéochimiques et la biodiversité (Houghton, 1990), représentant une cause majeure du changement climatique (IPCC, 2007).

En effet, la déforestation tropicale contribue aux émissions atmosphériques de gaz à effet de serre (GES) via la décomposition ou à la combustion de la biomasse forestière (FAO, 2020). En 2020, les tropiques ont perdu 12,2 millions d'hectares de couvert arboré, selon les données de l'Université du Maryland et disponibles sur Global Forest Watch (<https://www.globalforestwatch.org/map/>). Sur ces 12,2 millions d'hectares, 4,2 millions d'hectares de perte se sont produits dans les forêts tropicales primaires humides. Les émissions de carbone résultant de cette perte de forêt primaire sont estimées à 2.64 Gt CO<sub>2</sub> et environ 8% des émissions mondiales proviennent actuellement de la perte de couvert arboré dans les forêts tropicales (Global Forest Watch).

En **Afrique**, les émissions moyennes en CO<sub>2</sub> ont été estimées à 0,5GtC/an pour la période 2000-2005 (Canadell et al., 2009). Ces émissions résultent de la combustion de combustibles fossiles (0.26GtC/an) et du changement d'usage des sols (0.24GtC/an) (17% des émissions mondiales dues aux changements d'usage du sol, Canadell et al., 2009), ce dernier étant largement causé par la **déforestation** (Houghton, 2007). En Afrique centrale, les menaces qui pèsent sur les ressources forestières sont multiples : abattage des forêts périurbaines pour le bois de feu ; agriculture itinérante ; industries extractives comme l'exploitation minière et l'exploitation pétrolière qui ont non seulement des impacts directs (déforestation), mais qui causent également des impacts indirects liés au développement des infrastructures associées (e.g. routes) ; production d'agro-carburants se traduisant par la conversion d'importantes superficies à la monoculture du palmier à huile comme au Cameroun ou en République du Congo ; exploitation forestière



industrielle qui contribue à la fragmentation des massifs due à une présence humaine plus forte autour des camps d'exploitation et des réseaux routiers construits (Ernst et al., 2010).

Alors que l'importance d'inclure les réductions d'émissions dues à la déforestation tropicale dans la politique du changement climatique ne fait que croître, la Convention-Cadre des Nations Unies sur les Changements Climatiques (CCNUCC) a convenu en 2005 d'élaborer une nouvelle initiative appelant à des incitations économiques pour faciliter la réduction des émissions dues au déboisement dans les pays en développement (RED). Depuis, le concept a intégré la dégradation forestière, ainsi que la promotion de la gestion durable des forêts, de la conservation et du renforcement des stocks de carbone forestiers et est devenu « REDD+ » (« Reducing emissions from deforestation and forest degradation »). La REDD+ vise à fournir des incitations financières et autres appuis pour aider les pays en développement à réduire volontairement leurs taux de déforestation et de dégradation forestière et renforcer leurs stocks de carbone forestiers, réduisant ainsi leurs émissions de GES en deçà d'un niveau de référence (scénario hypothétique décrivant les émissions futures en l'absence de mesures REDD+) (Angelsen, 2009 ; Corbera et al., 2011 ; Alexander et al., 2011). Dans le cadre de la REDD +, chaque pays est appelé à formuler sa propre définition de la forêt pour les inventaires de GES.

La définition de la forêt adoptée dans la thèse est celle de la FAO qui considère la **forêt** comme un terrain d'une superficie d'au moins 0,5 hectare couvert à au moins 10 % par des arbres dont la hauteur à maturité est d'au moins 5 mètres FAO (2020). La déforestation quant à elle, fait référence à la conversion rapide des forêts en zones non forestières, alors que la **dégradation** implique généralement un changement de la structure forestière sans modification de l'utilisation des terres. Il n'existe pas de consensus définitif sur la définition de la dégradation. La définition de la dégradation adoptée dans la thèse est établie à partir de celle de l'**OIBT** (Organisation Internationale pour les bois tropicaux) qui définit la dégradation des forêts comme la réduction de la capacité d'une forêt de produire des biens et des services (OIBT 2002). L'OIBT précise qu'une forêt dégradée ne fournit qu'une quantité limitée de biens et services et ne conserve qu'une diversité biologique restreinte. Elle a perdu la structure, la fonction, la composition des essences et/ou la productivité normalement associées à la forêt naturelle (OIBT 2002). Selon la FAO (2011), c'est la définition la plus exhaustive.

Les facteurs courants de dégradation forestière comprennent la récolte de bois (légale et illégale), la collecte de bois de chauffage, les incendies et le pâturage animal dans la forêt empêchant la régénération de la forêt (fig. 1). La **dégradation** des forêts est une préoccupation majeure car le potentiel de séquestration du carbone est perdu et ce potentiel est largement sous-estimé. Les forêts dégradées subissent des changements structurels entraînant une réduction du potentiel de stockage du carbone, entraînant un biais dans les bilans carbone. Selon le rapport de la FAO de 2020 sur l'état des forêts mondiales, ce sont plus de 100 millions d'hectares de forêts qui sont affectés par les incendies de forêt, les ravageurs ou parasites, les maladies, les espèces invasives, la sécheresse et les événements météorologiques défavorables. Par ailleurs, Matricardi et al. (2020) montrent que la dégradation est dans 50% des cas un précurseur à la déforestation.




Figure 1 : forêt dense non perturbée (en haut à gauche) et cinq principaux facteurs de dégradation forestière : feux de forêt (et cultures sur brûlis), coupe sélective pour les bois nobles, collecte de bois de chauffage, maladie et pâturage animal qui empêche la régénération forestière.

En termes d'émissions de carbone, une estimation des émissions dues à la dégradation des forêts entre 2005 et 2010 dans 74 pays en développement totalisant une surface de 2,2 milliards d'hectares de forêts a été réalisée par Pearson et al. (2017). Les émissions annuelles ont été estimées à 2,1 milliards de tonnes de dioxyde de carbone, dont 53 % provenaient de la récolte de bois d'œuvre, 30 % de la récolte de bois de chauffage et 17 % des feux de forêt. Ces pourcentages variaient selon les régions : la récolte de bois atteignait 69 % en Amérique du Sud et centrale et 31 % en Afrique ; la récolte de bois de chauffage était de 35 % en Asie et de 10 % en Amérique du Sud et centrale ; et les incendies allaient de 33 % en Afrique à 5 % en Asie. Sur le total des émissions dues à la déforestation et à la dégradation des forêts, la dégradation des forêts en représentait 25 %. Dans 28 des 74 pays, les émissions dues à la dégradation des forêts ont dépassé celles dues à la déforestation. L'ampleur des émissions calculées indique que l'exclusion de la dégradation des forêts de la comptabilisation des GES aux niveaux national et international fausse la représentation de leur bilan de carbone. Les 74 pays dont les émissions dues à la dégradation des forêts sont les plus importantes sont affichés en figure 2.



climatiques défavorables au maintien d'une forêt, qui se transformerait peu à peu en savane aride (Marengo et al., 2018).

Outre son rôle dans le bilan carbone, la dégradation des forêts est à prendre au sérieux pour des raisons de santé publique. La fragmentation des forêts et les effets de lisière associés sont l'une des principales causes de la dégradation des forêts. 9 % des forêts mondiales se trouvent dans des fragments avec peu ou pas de connectivité. Environ 20 % de la superficie forestière mondiale se trouvent dans plus de 34 millions de parcelles à travers le monde – la grande majorité ayant une superficie inférieure à 1 000 hectares (FAO, 2020). La fragmentation des forêts crée une mosaïque d'îlots boisés séparés par des couloirs déboisés, ce qui augmente l'interaction entre les systèmes naturels et anthropisés et induit un risque élevé de **zoonose** (Goldberg et al., 2008). L'empiètement de l'homme sur les habitats naturels peut exacerber la propagation du virus des hôtes sauvages à l'homme. De 2004 à 2015, des épidémies d'Ebola en Afrique ont été localisées dans des "points chauds" (hotspot) de fragmentation des forêts, en raison d'une plus grande fréquence de contact entre les humains et les réservoirs d'infection, comme certaines espèces de chauves-souris (Rulli et al., 2017 ; Olivero et al., 2017).

Plus récemment, des analyses quantitatives ont combiné des caractéristiques de l'occupation et de l'utilisation des sols et les « points chauds » de chauves-souris hôtes du SRAS-CoV-2 en Chine (Rulli et al., 2021 ; Santini, 2021). Les auteurs montrent que la fragmentation des forêts, la production de bétail et la densité de l'urbanisation sont nettement plus élevées dans un rayon de 30 km autour des emplacements réels des chauves-souris *Rhinolophidae* (chauves-souris "fer à cheval"), seules espèces hôtes du SRAS-CoV-2, qu'ailleurs dans leur aire de répartition.

Selon le rapport de l'état des forêts mondiales de la FAO de 2020, la majorité des nouvelles maladies infectieuses affectant les humains, y compris le virus SARS-CoV2 qui a causé la pandémie de COVID-19, sont zoonotiques et leur émergence peut être liée à la perte d'habitat due au changement de la superficie forestière et à l'expansion des populations humaines dans les zones forestières, qui augmentent tous les deux l'exposition humaine à la faune.

Il est donc nécessaire de suivre la dégradation forestière tout autant que la déforestation. Cependant il est beaucoup plus difficile d'estimer la superficie affectée et les pertes de carbone causées par la dégradation des forêts que la déforestation, puisqu'elle n'implique pas de modification de l'utilisation des terres et le contexte forestier est préservé. A cela s'ajoute le fait que la dégradation est causée par une grande variété de processus avec des impacts différents, notamment l'exploitation forestière commerciale, l'extraction de bois de chauffage, la culture sous-couvert, le pâturage, les incendies et les effets de bord causés par la déforestation à proximité.

## **1.2. La télédétection pour le suivi de la déforestation en milieu tropical**

La télédétection est l'étude d'objets à distance. En raison de son observation globale, régulière et continue, elle est un outil adapté au suivi des surfaces terrestres. Elle permet notamment de mesurer et de cartographier la déforestation et la dégradation forestière, ou tout du moins d'en réduire les

incertitudes. Elle permet également d'estimer la biomasse forestière et ses changements pour améliorer notre compréhension du bilan mondial du carbone : en imagerie **optique**, les longueurs d'onde des domaines visible et infrarouge permettent d'établir des indices spectraux, qui sont ensuite combinés et utilisés en données d'entrée dans les procédures de classification ou encore corrélés aux mesures de carbone forestier faites au sol (e.g. Lu et Batistella, 2005 ; Lu, 2005). En imagerie **radar** (*RADio Detection And Ranging*), les micro-ondes du signal mesurent la structure verticale de la forêt pour établir les estimations de biomasse par allométrie (e.g. Mette et al., 2002 ; Le Toan et al., 2004). **Ces mesures de surface forestière perdue et ces estimations de stock de carbone, faites à terre et par télédétection, ont pour principal enjeu de quantifier les émissions de carbone engendrées par la déforestation.**

Ainsi, les programmes internationaux de réduction des émissions (notamment le programme REDD+) se sont principalement concentrés sur la déforestation, qui est plus facile à détecter et donc à mesurer et à surveiller que la dégradation des forêts. Vue du ciel, la déforestation est une surface claire et rasée dans un environnement vert.

Par exemple, au **Brésil**, les données de télédétection ont notamment permis de détecter des zones de **déforestation** illégale en Amazonie brésilienne (Skole & Tucker, 1993). Notamment, en imagerie optique, des suivis continentaux de la couverture végétale ont été possibles dès 1978 avec le lancement du premier satellite NOAA équipé d'un radiomètre imageur à basse résolution (AVHRR). Depuis, des applications opérationnelles sous la forme d'alertes en temps quasi-réel ont vu le jour, comme par exemple, le projet PRODES (<http://www.obt.inpe.br/prodes/>) utilisant les données satellitaires du capteur Landsat Thematic Mapper durant plusieurs décennies afin de suivre la déforestation amazonienne au Brésil.

Global Forest Watch (GFW) est une application web à code source ouvert permettant de suivre les forêts mondiales en temps quasi réel grâce aux alertes de déforestation<sup>1</sup> (Hansen et al., 2013). La plateforme GFW a été utilisée dans un certain nombre d'applications comme mesurer les taux de déforestation mondiaux et détecter, surveiller les activités de défrichement illégales, par exemple en Indonésie. Les données sur les incendies actifs de la NASA, affichées dans GFW Fires, ont été utilisées pour identifier les incendies illégaux à l'origine de la crise de la brume (« Haze crisis ») en Asie du Sud-Est en 2015, révélant qu'environ 35 % des incendies en Indonésie se sont produits dans des concessions agricoles.

En **Afrique centrale**, qui abrite la deuxième plus grande étendue de forêt tropicale humide au monde (Mayaux et al., 1998), des données optiques comme les données Landsat de 30 m de résolution ont permis d'estimer un taux annuel de **déforestation** dans le bassin du Congo à 0,13 % de la surface totale pour la période 1990-2000, taux ayant doublé pour la période 2000-2005 (Ernst et al., 2010). Plusieurs initiatives visant à suivre et à protéger les forêts ont vu le jour. Plus précisément, l'Observatoire des forêts d'Afrique centrale (OFAC), une initiative de multiples parties prenantes du Partenariat sur les forêts du bassin du Congo (PFBC, 2006), vise à mettre en commun les connaissances et les données disponibles nécessaires pour suivre les différents aspects des forêts d'Afrique centrale.

Représentant environ un quart du continent africain, l'**Afrique de l'Ouest** comprend un vaste éventail d'écosystèmes, de régions bioclimatiques et d'habitats allant du désert à la forêt tropicale humide. Dans

---

<sup>1</sup> <https://www.globalforestwatch.org/map/>

le but de cartographier les changements de l'utilisation et de l'occupation des terres, un atlas des paysages de l'Afrique de l'Ouest a été réalisé par des experts d'institutions de 17 pays de l'Afrique de l'Ouest en partenariat avec le Comité Inter-états de Lutte contre la Sécheresse dans le Sahel (CILSS, 2016), l'U.S. Agency for International Development West Africa (USAID/WA) et l'U.S. Geological Survey (USGS). L'ouvrage met en évidence les modifications qui ont eu lieu dans les 17 pays, au cours des quatre dernières décennies.

Les approches actuelles de suivi des écosystèmes forestiers sont majoritairement basées sur des recensements des ressources forestières par imagerie **optique**. Cependant, les possibilités de valorisation de l'imagerie optique sont très fortement limitées par la présence de nuages. Les forêts tropicales se trouvant pour la plupart dans les zones les plus nuageuses de la planète, des mois peuvent passer sans que la production d'images optiques ne permette une visualisation du couvert sous-jacent et une détection suffisamment fiable des changements d'usage des terres (Morton et al., 2011).

La télédétection radar a permis de s'affranchir de cette difficulté. Par sa capacité à détecter dans toutes conditions météorologiques, de jour comme de nuit, la télédétection **radar** est particulièrement bien adaptée pour le suivi des régions tropicales, sujettes à un fort couvert nuageux la moitié de l'année. Les capteurs satellitaires actifs de type Radars à Synthèse d'Ouverture (RSO), plus connus sous l'abréviation anglo-saxonne SAR (Synthetic Aperture Radar), opèrent dans le domaine des hyperfréquences, c'est-à-dire dans des longueurs d'onde centimétriques. Ils communiquent des informations complémentaires à celles obtenues par les systèmes optiques. La télédétection radar satellitaire a réellement débuté en 1991 avec les satellites ERS développés par l'Agence Spatiale Européenne et depuis, la mise en orbite de bon nombre de capteurs radar permis des observations de la Terre en bande X, C, et L (respectivement 2 cm, 6 cm et 20 cm en longueur d'onde) sous différentes résolutions spatiales (du mètre au kilomètre), résolutions temporelles (de 6 à 35 jours), polarisations, etc. Même si sa capacité à pénétrer le couvert végétal dépend des longueurs d'onde utilisées, le domaine des micro-ondes est particulièrement adapté au suivi des forêts grâce à sa sensibilité à la géométrie de la végétation.

De nombreuses méthodes ont été proposées pour la détection de déforestation sur la base de ces données (Saatchi et al., 1997 ; Saatchi et al., 2002 ; Mermoz & Le Toan, 2016 ; Deutscher et al., 2017 ; Bouvet et al., 2018 ; Cremer et al., 2020 ; Doblas et al., 2020 ; Hirschmugl et al., 2020), et parfois, combinées aux données optiques (Reiche et al., 2013 ; Reiche et al., 2015 ; Reiche et al., 2018).

Depuis 2015, des mosaïques mondiales annuelles d'images ALOS PALSAR 2 en bande L de 2007 à 2020 sont mises à disposition (<https://www.eorc.jaxa.jp/ALOS-2/en/about/palsar2.htm>). ALOS-1 est un satellite de télédétection japonais lancé en 2006 et dont la mission prit fin en 2011. Dans sa charge utile, l'instrument PALSAR (Phased Array L-band Synthetic Aperture Radar) est un radar à synthèse d'ouverture. Le radar PALSAR-2 est une mise à niveau de son prédécesseur et a été lancé en 2014. Par leur longueur d'onde (~20 cm) et les 2 polarisations HH et HV proposées, les images ALOS-1 et 2 sont très pertinentes pour le suivi des forêts tropicales : non seulement l'onde incidente pénètre davantage la canopée et les houppiers denses qu'en bande C en raison de la plus grande longueur d'onde, mais la configuration de ces polarisations est très adaptée aux formes dièdres des arbres, ce qui leur confère une grande sensibilité aux changements structurels des forêts. Ces données radars générées à une

résolution spatiale de 25 m, fournissent une cartographie binaire forêt/non-forêt, sur la base des différences de structure de la forêt et des conditions d'humidité de la végétation et de la surface ([https://www.eorc.jaxa.jp/ALOS/en/palsar\\_fnf/fnf\\_index.htm](https://www.eorc.jaxa.jp/ALOS/en/palsar_fnf/fnf_index.htm)). En utilisant des seuils de rétrodiffusion spécifiques à chaque région, ces cartes annuelles de couvert forestier et non forestier ont notamment permis de produire des cartes de pertes forestières (Shimada et al., 2014).

### 1.3. La difficulté de cartographier des changements plus subtils du couvert forestier

La distinction entre forêts et terres déboisées traditionnellement utilisée pour cartographier l'état des forêts ne reflète pas la complexité de la situation. Un gradient complet existe dans ces forêts, allant du bien conservé au sévèrement dégradé (fig. 3, extraite de Morales-Barquero et al., 2014). La dégradation des forêts peut être définie de nombreuses manières. Dans le contexte de la REDD+ de la CCNUCC, la dégradation des forêts entraîne toute perte directe, anthropique et persistante de la densité en carbone au fil du temps dans les forêts restantes. La dégradation est un processus et prend différentes formes, notamment dans les formations forestières ouvertes résultant d'activités humaines comme le surpâturage, la surexploitation (pour le bois de chauffage ou le bois), les feux répétés ou les attaques d'insectes, de maladies, de parasites végétaux ou d'autres sources naturelles comme les cyclones. Dans la plupart des cas, la dégradation ne montre pas une diminution de la superficie de la végétation ligneuse, mais plutôt une réduction progressive de la biomasse, des modifications dans la composition des espèces et/ou une dégradation des sols. Les pratiques d'exploitation non durables peuvent contribuer à la dégradation si l'extraction d'arbres matures ne s'accompagne pas de leur régénération par exemple.




Figure 3 : Courbe de succession forestière extraite de Morales-Barquero et al. (2014).

L'impact de la dégradation peut se traduire par des changements structurels à petite échelle dans le couvert et la hauteur du couvert, par des perturbations subtiles des services écosystémiques, ou par une

perte à grande échelle de biomasse. Différents types de forêts réagiront différemment au changement, avec un taux de régénération variable, en fonction de l'emplacement et du type, de l'intensité et de l'étendue de la dégradation. À ce titre, une stratégie de suivi unique peut ne pas être appropriée pour une application à l'échelle mondiale pour tous les types de forêts : il s'agira plutôt de développer une approche spécifique à chaque région.

La nécessité de mener un suivi sur la dégradation des forêts tropicales est apparue dans les années 1990 alors que l'abattage sélectif et les dommages causés par les feux n'étaient pas pris en compte dans les études de déforestation. L'abattage sélectif a un impact important sur l'ensemble de l'écosystème forestier, avec des dégâts sur les arbres restants, des changements dans la diversité des espèces végétales et animales, des impacts sur le sol et également sur le stockage du carbone (Nepstad et al., 1999). Mais la dégradation forestière peut prendre d'autres formes et de nombreuses définitions de la dégradation forestière existent dans la littérature (Sasaki & Putz, 2009). Une sélection de définitions est fournie par la FAO<sup>2</sup>.

La nature complexe des modes de dégradation des forêts et la repousse rapide (régénération) sont les principaux obstacles dans le choix d'une définition commune de la dégradation forestière, et par conséquent, dans l'interprétation et la cartographie des perturbations des forêts tropicales. Par exemple, la dégradation des forêts est parfois définie comme une perte de biodiversité, comme une émission de gaz à effet de serre et/ou une diminution des biens et services écosystémiques. Mais interpréter la dégradation comme une perte d'attributs ou de fonctions, même si elle est intuitive, n'est pas suffisamment précise pour distinguer les nombreux états que les forêts peuvent occuper. Par exemple, les forêts se régénérant à la suite de perturbations naturelles, ou les forêts secondaires repoussant sur des terres autrefois défrichées, pourraient être classées comme dégradées parce que leur productivité ou leur prestation de services est réduite par rapport à une forêt mature "naturelle" (Ghazoul et al., 2015). La dégradation des forêts peut être provoquée par des perturbations naturelles (chablis, glissements de terrain, ouragans etc.) ou des perturbations humaines (coupe sélective, feu dans le sous-étage végétal sous la canopée etc.).

**Ces différents degrés de dégradation des forêts rendent la mesure des variations des stocks de carbone plus complexe et plus coûteuse que la mesure de la perte de carbone due à la déforestation.** La dégradation peut être difficile à détecter à la fois par les techniques de télédétection et les observations sur le terrain (Chazdon et al., 2016 ; Putz & Redford, 2010 ; Thompson et al., 2013 ; Ghazoul et al., 2015).

Un suivi à long terme est essentiel pour distinguer les forêts dégradées de celles restées intactes. Le type de dégradation peut, dans certaines circonstances, être identifié sur une image à date unique. Cependant, une série temporelle de données satellitaires (observations mensuelles ou intra-annuelles) est généralement nécessaire pour mieux saisir la dynamique du couvert forestier et/ou les variations des stocks de carbone. Généralement, deux approches principales sont rencontrées :

---

<sup>2</sup> [www.fao.org/docrep/009/j9345e/j9345e08.htm](http://www.fao.org/docrep/009/j9345e/j9345e08.htm)



1. La détection et la caractérisation de la dégradation par les modifications du couvert forestier, ou par le biais d'indicateurs (proxy) de ces modifications (présence de routes ou chemins linéaires à proximité, trouée dans les houppiers etc.) ;
2. La quantification de la perte en biomasse aérienne, en tant qu'étape intermédiaire de l'estimation des émissions de carbone produites.

Les différentes approches tentent de stratifier la forêt par type ou intensité de dégradation ou utilisent des **indicateurs de changement**. Les perturbations des forêts, résultant de l'exploitation forestière, du brûlage, des maladies ou des infestations d'insectes, peuvent être suivies par des approches de télédétection qui détectent les **changements du couvert**.

Les méthodes actuelles analysent les changements de réponse spectrale, les fractions spectrales et les indices, et tentent de séparer les forêts dégradées et intactes. L'abattage sélectif ou à haute intensité entraîne une fragmentation du couvert forestier et les méthodes de télédétection visent à détecter les clairières dans le couvert. Des indicateurs, sous la forme de routes forestières, de sentiers et de plateformes logistiques, fournissent des preuves de l'activité de déboisement ou l'extraction de bois et diverses méthodes, y compris les fractions spectrales, le filtrage spatial et les mesures de proximité, sont utilisées pour identifier leur progression. L'état de l'art sur la détection des forêts dégradées et sur les méthodes mentionnées est détaillé au chapitre 3.1.

#### **1.4. Problématique et hypothèses de travail**

Les travaux de la thèse ont été réalisés dans le cadre d'un partenariat entre l'Institut interdisciplinaire de recherche en énergie de Paris (LIED) et IGN FI, une société d'ingénierie en information géographique (partenaire export de l'IGN - Institut national de l'information géographique et forestière). Les projets de cartographie d'occupation du sol portés par IGN FI se concentrent dans les pays en voie de développement et comportent généralement une grande part de transfert de compétences vers les pays bénéficiaires (voir l'annexe A.2 sur les formations données durant la thèse dans les pays partenaires).

Les méthodes de référence actuelles que l'on rencontre dans les projets de cartographie d'occupation des sols (OCS) - Land Cover (LC) - pour identifier et localiser les forêts dégradées reposent sur la photo-interprétation. Cette approche conventionnelle est communément utilisée dans les projets de certification des réductions d'émissions de carbone. Elle prend généralement en compte la physionomie (forme, taille, couleur, texture) et la structure (motif, association, site) d'un peuplement forestier, mais aussi des informations contextuelles et temporelles afin de déterminer si son état est dégradé ou non. Des éléments secondaires peuvent indiquer un habitat dégradé, tels que la présence à proximité de cultures, des routes, des pistes, des cours d'eau, etc. Bien que cette procédure soit robuste et minutieuse, la numérisation manuelle des zones dégradées est extrêmement chronophage et les points de contrôle au sol montrent des failles sur le plan thématique, notamment dans les classes forestières.

La bonne exécution d'un projet est un compromis entre un calendrier de production et une production finale de qualité, ici la recommandation du Groupe d'experts intergouvernemental sur l'évolution du climat

(GIEC). Le projet de thèse s'est conformé aux méthodologies VCS (Verified Carbon Standard), qui sont actuellement les plus utilisées. Le programme VCS fournit un cadre pour la validation indépendante des projets et des programmes, ainsi que pour la vérification de la réduction et de l'élimination des émissions de GES. Fondé en 2006, le programme VCS est un document de consultation et une norme à utiliser par le marché. La version 4 de VCS est la plus récente et a été publiée en 2019. Les projets développés dans le cadre du programme VCS doivent ainsi suivre un processus d'évaluation rigoureux afin d'être certifiés. Les projets VCS couvrent un large éventail de secteurs, notamment les énergies renouvelables (comme les projets éoliens et hydroélectriques), la foresterie (comme l'évitement de la déforestation), etc. Le présent travail de thèse peut s'insérer dans la méthodologie VM0037 « Méthodologie pour la mise en œuvre d'activités REDD+ dans les paysages touchés par la déforestation et la dégradation »<sup>3</sup> et se conformer à ses exigences de cartographie d'occupation du sol. La méthodologie VCS exige une précision globale minimale de 85% et une précision minimale de chaque classe de 80%.

Des limites découlent des contraintes de temps dans un calendrier de production :

- i. Un photo-interprète considère de nombreuses classes d'occupation du sol dans le paysage, il n'est pas à l'abri d'omissions sur certaines classes et sur des changements secondaires, en particulier lorsque l'accent est mis sur les changements d'utilisation des terres plus francs comme la déforestation, l'extension urbaine ou l'expansion agricole ; les changements tenus d'une forêt dense à une forêt dégradée nécessitent plus d'attention et d'analyse de l'image notamment temporelle pour exclure l'effet saisonnier, et peuvent être manqués ;
- ii. Généralement, l'étude d'une image satellite unique avec une gamme spectrale étroite comme SPOT-6 ne permet pas d'identifier clairement la dégradation des forêts dans la mesure où elle est graduelle et progressive dans le temps et dans l'espace.

L'objectif de cette thèse est de cartographier les forêts dégradées, due à l'exploitation sélective et à la fragmentation des forêts, d'abord :

- i. En complétant les méthodes de photo-interprétation puis,
- ii. En proposant des méthodes aussi automatiques que possible, c'est-à-dire qui réduisent l'effort de photo-interprétation à fournir par les opérateurs cartographes. Les problématiques de cette thèse doivent également privilégier des données d'imagerie et des outils libres pour contribuer au renforcement et à la durabilité des connaissances et des compétences dans les pays du Sud, puisque le transfert de connaissance fait partie des missions d'IGN FI (voir annexe A.2 sur les formations données).

De nombreux travaux de télédétection se basent sur la saisonnalité de la radiométrie pour déterminer l'occupation du sol (Bartholomé & Belward, 2005 ; Kaptue et al., 2010 ; Viennois, 2011 ; Ramirez-Cuesta et al., 2021). Les données Sentinel-2 sont acquises depuis 2015, fournissant entre 6 et 7 années de données à haute résolution temporelle. Ces travaux de thèse visent à étudier l'apport de la haute résolution temporelle d'images optiques issues de la constellation Sentinel pour la cartographie

---

<sup>3</sup> <https://verra.org/methodologies/>

d'occupation du sol en milieu tropical et en particulier la détection des forêts dégradées, vis-à-vis de l'utilisation d'une image mon-date comme dans les projets OCS antérieurs.

Les problématiques de cette thèse reposent sur deux **hypothèses de travail** :

- a. Il existe un besoin de méthodologie de détection des forêts dégradées semi-automatique et/ou automatique pour l'opérabilité dans les projets d'occupation du sol.
- b. Les forêts dégradées pourraient montrer des changements spatiaux de la radiométrie grâce à la gamme élargie de réflectances spectrales de Sentinel-2.

Les travaux de cette thèse ont pour principaux **objectifs** :

- i. de compléter les techniques de photo-interprétation existantes dans les projets d'OCS, notamment pour identifier les forêts dégradées.
- ii. d'établir une méthode ayant pour objectif de produire des cartes de forêts dégradées à un coût minimum de photo-interprétation pour une production moins chronophage et moins coûteuse.
- iii. d'établir une méthode aussi transférable que possible, d'une année à l'autre et d'un massif à l'autre.

La littérature propose un certain nombre de méthodes de détection de forêts dégradées, nous en testerons les principales avant d'évaluer si elles sont robustes et opérationnelles. Enfin, la combinaison d'indices de végétation, d'indices biophysiques, l'apport de la dimension temporelle et l'apport de l'information régionale (contextuelle) seront testés pour cartographier les formations végétales dans le but d'adapter au contexte les méthodes de détection de forêts dégradées et de différencier les changements liés à la dégradation et ceux liés aux variations saisonnières.

Ces **problématiques** sont synthétisées en six questions :

- i. Que peut apporter la radiométrie Sentinel dans l'amélioration des techniques de photo-interprétation des forêts dégradées ? Comment l'exploiter au mieux ?
- ii. Quelles méthodes existantes appliquées à l'imagerie Sentinel semblent pertinentes pour la détection des forêts dégradées ?
- iii. Que peut apporter la haute résolution temporelle à la détection des forêts dégradées ?
- iv. Quelle est l'influence du voisinage spatial dans la catégorisation d'un pixel en forêt dégradée ?
- v. Peut-on développer une méthode semi-automatique de détection des forêts dégradées qui minimise le besoin en photo-interprétation (et de digitalisation) et qui soit à la fois généralisable ?
- vi. Peut-on développer des méthodes de détection des forêts dégradées basées sur des outils libres pour favoriser leur diffusion auprès des utilisateurs ?

Les réponses à ces interrogations nous aideront à aborder l'analyse du signal optique dans les forêts dégradées puis l'influence du contexte dans leur détection.

## 1.5 Choix d'utilisation d'outils libres

Le travail de recherche de thèse CIFRE (Conventions Industrielles de Formation par la REcherche) est accompagné par l'entreprise IGN FI, société d'ingénierie spécialisée dans l'élaboration et la réalisation de projets géomatiques à l'international, notamment dans le domaine de cartographie d'occupation du sol (OCS). La construction des projets de cartographie d'OCS à IGN FI est généralement réalisée par la mise en place d'une équipe d'opérateurs cartographes nationaux, bénéficiant d'un accompagnement technique et d'un transfert complet de compétences et de connaissances. Cet accompagnement est assuré pendant la durée du projet par une équipe d'experts multidisciplinaires d'IGN FI en photo-interprétation, en occupation du sol et en Système d'Information Géographique (SIG) afin de rendre, à terme, l'équipe locale la plus autonome possible et de contribuer ainsi au renforcement et à la pérennisation des connaissances et des compétences au pays partenaire. Cet accompagnement comprend une série de missions de formation sur place (syllabus des formations données durant la thèse en Annexes A.2).

Les analystes nationaux ont par conséquent besoin de systèmes de suivi du couvert terrestre qui soient libres, ouverts et interopérables. C'est pourquoi les travaux de thèse ont été entièrement réalisés avec des images satellites et logiciels libres et gratuits. La constellation Sentinel-2 a été préférée à d'autres imageries optiques (SPOT, Planet, Pléiades) qui, malgré de meilleures résolutions spatiales, ne sont pas gratuites.

Un logiciel libre est un "logiciel qui offre et garantit les quatre libertés suivantes : utilisation, étude, modification et duplication en vue de sa diffusion. Ceci est permis techniquement grâce à l'accès au code et légalement grâce à la licence libre qui l'accompagne. Ces quatre libertés favorisent la transparence, la confiance, l'échange, le partage et la collaboration au sein de communautés"<sup>4</sup>.

Promouvoir les logiciels libres (et plus largement les technologies ouvertes et interopérables) dans les travaux de cette thèse constitue un des objectifs principaux de ce manuscrit. Le Libre (*free software* en anglais), né dans les années 80, défend ainsi le "partage et la collaboration entre développeurs, la possibilité pour les utilisateurs de contrôler leur informatique et la production de technologies socialement utiles"<sup>5</sup>.

Par exemple, QGIS<sup>6</sup> qui est une application SIG professionnelle qui repose sur un logiciel libre et ouvert, est développée par une équipe de volontaires et d'organisations. Orfeo ToolBox (OTB)<sup>7</sup> est un projet open-source pour la télédétection développé par le Centre National d'Etudes Spatiales (CNES). Conçu par et pour la communauté géospatiale open source : il propose une très large gamme d'outils de traitement d'images optiques, multispectrales et radar à haute résolution. Une grande variété d'applications est disponible : de l'ortho-rectification ou du pansharping à la classification, au traitement radar etc. Surtout, tous les algorithmes d'OTB sont accessibles depuis QGIS, Python, ou encore en ligne

---

<sup>4</sup> <https://framasoftware.org/fr/>

<sup>5</sup> *Utopie du logiciel libre* de Sébastien Broca

<sup>6</sup> [www.qgis.org/fr/](http://www.qgis.org/fr/)

<sup>7</sup> <https://www.orfeo-toolbox.org/>

de commande. Piloté par la communauté, extensible, sa grande force est qu'il est fortement documenté. Dans le travail de thèse, les algorithmes de classification ont été implémentés en langage Python.

Du côté des pré-traitements des images Sentinel-2, l'ESA développe des boîtes à outils libres et open source pour l'exploitation scientifique des missions Sentinel. La boîte à outils Sentinel - ou SNAP pour Sentinel Application Platform - qui est une architecture commune à toutes les Sentinel Toolboxes comprend un ensemble d'outils de traitement, de lecture et d'écriture de données Sentinel ainsi que d'autres données satellitaires.

Tout le long des travaux de thèse, les traitements et les analyses des images optiques ainsi que les rendus cartographiques ont été effectués avec les outils d'Orfeo ToolBox, le logiciel SNAP<sup>8</sup> développé par l'ESA pour les données Sentinel ; et le logiciel QGIS. Les graphiques, les analyses temporelles, statistiques ainsi que les développements algorithmiques ont été programmés en Python.

## 1.6. Organisation du manuscrit

Ce premier chapitre a montré l'importance des forêts dégradées et la difficulté de les cartographier, tant dû au grand nombre de définitions de forêts dégradées rencontrées dans la littérature, qu'à la difficulté de les percevoir depuis l'espace. Les principaux objectifs de la thèse ont été énoncés.

Le chapitre 2 présente les sites d'étude en Guinée ainsi que le contexte général de la thèse, à savoir le projet de Zonage Agroécologique de Guinée (ZAEG) dont proviennent les définitions que nous avons utilisées pour les forêts dégradées en Guinée. Plus précisément, sont décrits les données satellitaires, les données relevées sur le terrain en avril 2019 en Guinée forestière, les données auxiliaires de référence qui ont servi de point de départ de la thèse et les données images utilisées dans les travaux de thèse. Une partie du chapitre est consacrée au développement d'une méthode de photo-interprétation basée sur l'imagerie Sentinel-2.

Le chapitre 3 s'intéresse à la détection semi-automatique des forêts dégradées à partir des images Sentinel-2. Un état de l'art et une comparaison de méthodes de détection y seront détaillés.

Le chapitre 4 présente les travaux liés aux réseaux neuronaux convolutifs pour la détection semi-automatique des forêts dégradées. La construction d'un nouveau jeu de données labellisé y sera décrite, ainsi que l'implication de la science citoyenne pour l'implémentation d'un modèle d'apprentissage en profondeur. Ce modèle sera comparé à 2 autres réseaux avant d'être soumis à la procédure de validation indépendante par IGN FI des cartes produites par le modèle.

Enfin, le chapitre 5 présente les conclusions et les perspectives des travaux de thèse.

---

<sup>8</sup> <http://step.esa.int/main/toolboxes/snap/>

## Chapitre 2

### Détection des forêts dégradées par photo-interprétation en Guinée : amélioration de la méthode

Le travail de thèse s'inscrit dans le cadre du projet de Zonage Agroécologique de Guinée (ZAEG) porté par IGN FI, et financé par l'Agence Française du Développement. Dans le projet ZAEG, la cartographie des forêts dégradées repose sur les méthodes existantes : la photo-interprétation de l'image satellite, suivie de la digitalisation manuelle des forêts dégradées. Dans ce chapitre, nous nous intéressons à évaluer puis améliorer cette méthode.

La section 2.1 développe les particularités de la Guinée forestière, où se situe le massif de Ziama, site d'étude principal de la thèse, et qui est avec Diécké et le Mont Nimba l'un des trois massifs protégés de cette région. La section 2.2 décrit le contexte général des travaux de la thèse, en particulier, le projet ZAEG, dont l'objectif est de cartographier l'occupation du sol de la Guinée et incluant une classe de forêt dégradée dont l'évaluation et l'amélioration sont l'objectif de cette thèse. La section 2.3 posera les définitions des forêts dégradées et des systèmes arborés retenues dans le projet et pour la thèse. La section 2.4 présente en détail les données de terrain collectées dans le massif de Ziama, et la section 2.5 évalue en détails les conflits thématiques constatés dans la carte issue du projet ZAEG et les observations de terrain. Enfin, la section 2.5 décrit les données satellitaires utilisées ainsi que les traitements réalisés pour la création d'un nouveau jeu de données photo-interprété. Nous y examinons les radiométries de Sentinel-2 sur les forêts dégradées et les forêts denses et en dérivons, une méthode de photo-interprétation améliorée pour mieux visualiser et délimiter les zones de forêts dégradées, tirant partie des spécificités spectrales de Sentinel-2 et de ses capacités de revisite.

#### 2.1. Site d'étude : la Guinée forestière

La République de Guinée, pays côtier d'Afrique de l'Ouest, est située entre les 7<sup>ème</sup> et 11<sup>ème</sup> degrés de latitude nord, et les 7<sup>ème</sup> et 15<sup>ème</sup> degrés de longitude ouest. Elle possède une façade maritime de 300 km sur l'océan Atlantique et est bordée par la Guinée Bissau au nord-ouest, le Sénégal au nord, le Mali au nord et au nord-est, la Côte d'Ivoire à l'est et le Liberia et la Sierra Leone au sud-est. Le pays, d'une surface de 250 130 km<sup>2</sup> est divisé en quatre régions naturelles différenciées par le relief, le climat, les sols et le peuplement, à l'origine de particularités ethnoculturelles : la Guinée maritime, la Moyenne Guinée, la Haute Guinée et la Guinée forestière (Fig. 4).

La situation actuelle du milieu naturel de la Guinée se traduit par un constat de dégradation généralisée (Sow, 2003), autant des forêts denses du Sud que des forêts sèches et des savanes arborées du Nord ou que des plateaux herbeux du Fouta Djallon. Le rapport 2020 de la FAO estime la surface de forêt plantée à 57 000 ha en Guinée, sur une surface forestière totale de 6 189 000 ha, la forêt naturellement régénérée représentant les 6 132 000 ha restants.

En Guinée Forestière, zone de prédilection de la forêt à valeur commerciale, seuls trois massifs forestiers subsistent, la forêt classée de Ziama, celle de Diécké, et la forêt classée du Mont Nimba à la frontière ivoirienne ainsi que des fragments clairsemés (Delorme, 1998) (fig. 5). La partie nord présente des savanes peu arborées, avec quelques ripisylves ainsi que des forêts sacrées.

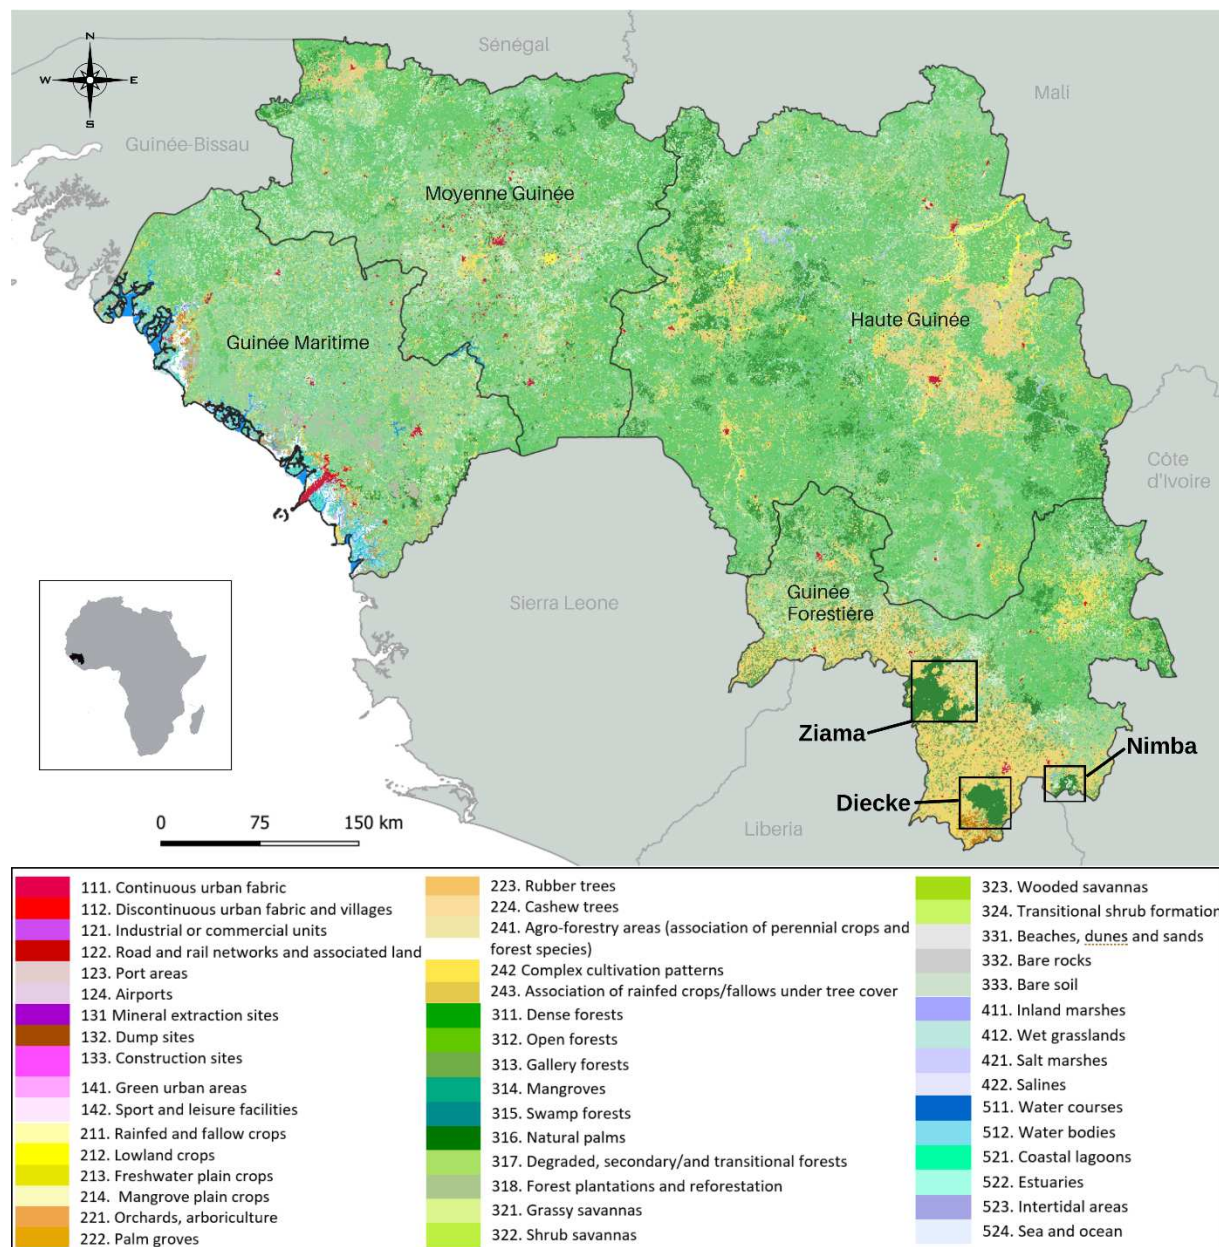


Figure 4 : Carte 2015 de l'occupation et de l'utilisation des sols (OCS) de la Guinée montrant la localisation du site d'étude dans les massifs de Ziama, Diécké et Nimba, avec une forêt pluviale exposée à la mousson. La carte OCS 2015 a été produite dans le cadre du projet Zonage Agro-écologique de la Guinée (ZAEG), avec 47 classes adaptées de l'European Corine Land Cover. Les cartes présentées dans tout le manuscrit sont projetées au UTM zone 29 nord, sur l'ellipsoïde WGS 1984. Source : projet ZAEG (voir partie 2.2).

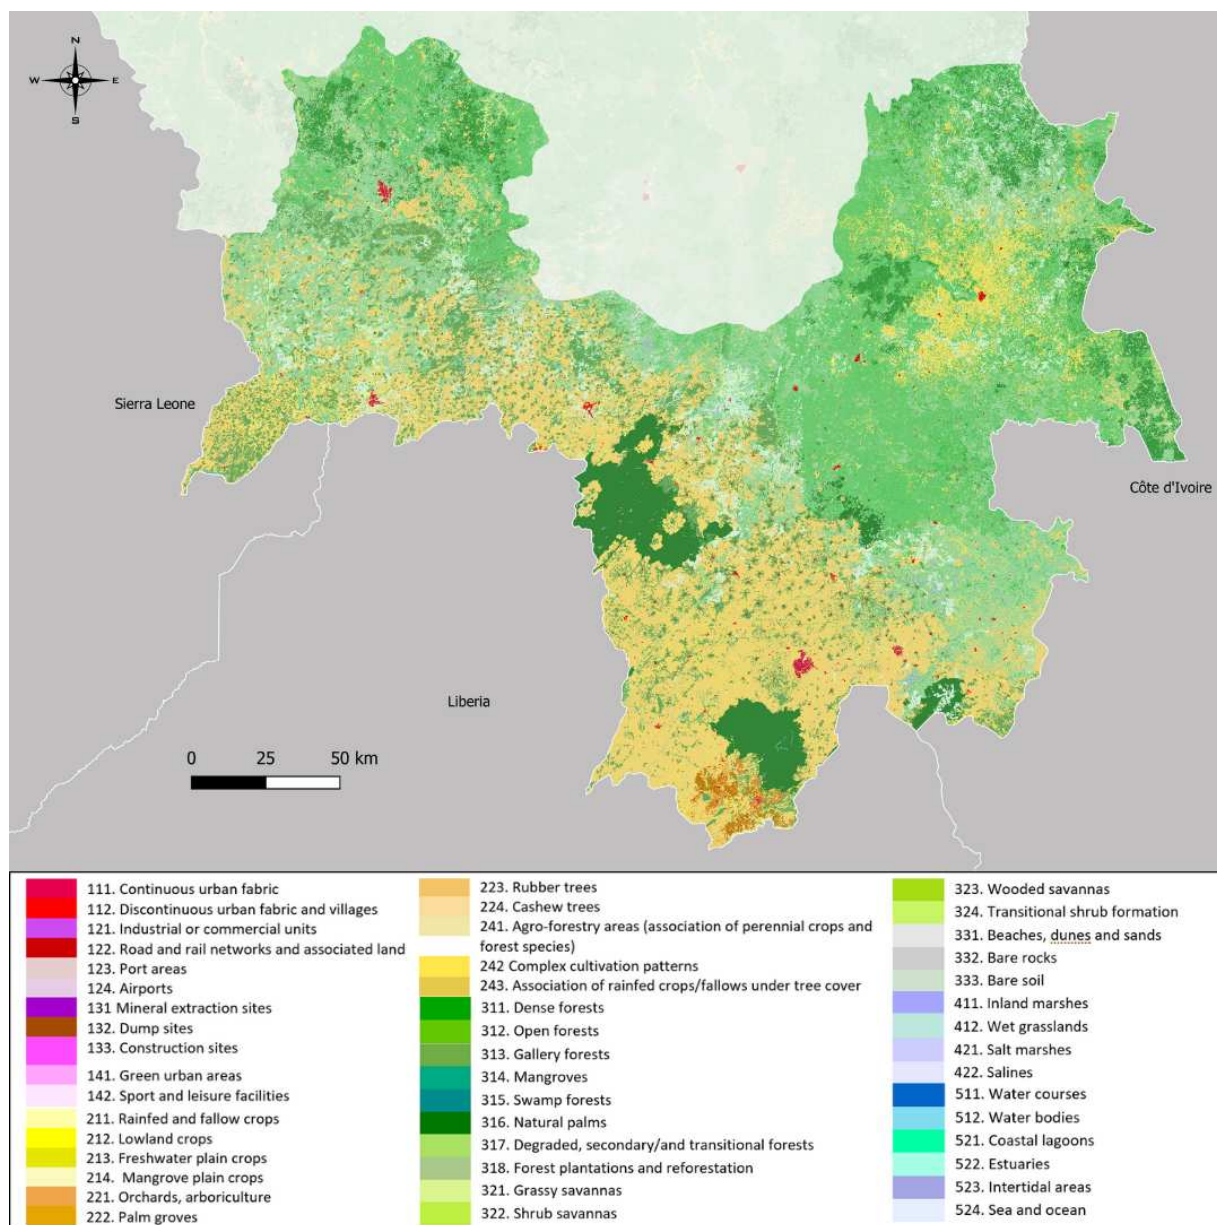


Figure 5 : Carte 2015 de l'occupation et de l'utilisation des sols (OCS) de la Guinée forestière. Source : projet ZAEG.

La Guinée forestière doit son nom à la présence de forêts denses au début du 20<sup>ème</sup> siècle. Elle est soumise à un climat tropical humide avec des précipitations annuelles estimées à 1750-2000 mm, une exceptionnelle longueur de la saison des pluies (entre 7 et 9 mois), une courte saison sèche (de décembre à février) et une température moyenne annuelle de 24°C (Boulvert, 2003). La végétation spontanée est de type forêt dense humide sempervirente (Boulvert, 2003). La Guinée Forestière enregistre les premières pluies dès la fin avril alors que la région de Siguiri, plus au nord, n'est arrosée qu'à partir de la fin mai. Dans ce contexte climatique, le paysage végétal est caractérisé par une transition lente de la savane arborée/boisée au nord vers la forêt tropophile au sud (sempervirente tropicale).

La région est située dans une zone de collines d'altitude comprise entre 500 et 800m, dont le point culminant, le Mont Nimba (1752 mètres), se trouve au sud-est de la région ; ses sols sont essentiellement ferrallitiques développés sur un socle de roches granitiques (Boulvert, 2003) représentant l'un des plus



importants et des plus riches gisements mondiaux de minerai de fer. La mise en exploitation de ces gisements a permis un rapide développement économique, mais a mis en péril l'environnement du Mont Nimba. En 1981, la réserve naturelle intégrale a été classée réserve de biosphère et site du patrimoine mondial de l'UNESCO. À la fin des années 1980, la Guinée a exprimé son désir d'exploiter les gisements de fer du Mont Nimba, suscitant l'inquiétude des organismes de conservation internationaux. L'octroi de concessions minières a été annoncé en 1992 et elle incluait des parties du site du patrimoine mondial. Cette même année, le mont Nimba fut inscrit sur la liste du patrimoine mondial en péril, à cause des projets miniers et de l'arrivée massive de réfugiés de guerre en provenance du Liberia<sup>9</sup>.

Restée longtemps très enclavée, la Guinée Forestière est aujourd'hui plus largement ouverte aux échanges avec le reste du pays et en est la région qui connaît l'urbanisation la plus rapide. Autour de la métropole régionale, N'Zérékoré, un faisceau de villes secondaires se développe rapidement, en partie dû aux populations réfugiées du Libéria et de la Sierra Léone et au regain d'activités qu'elles génèrent. La région exporte les produits des bananiers plantains, palmiers à huile et hévéas. D'autres cultures, comme celles du café ou du cacao, sont relancées au sein de petites unités familiales et connaissent aujourd'hui un développement notable (Camara et al., 2012).

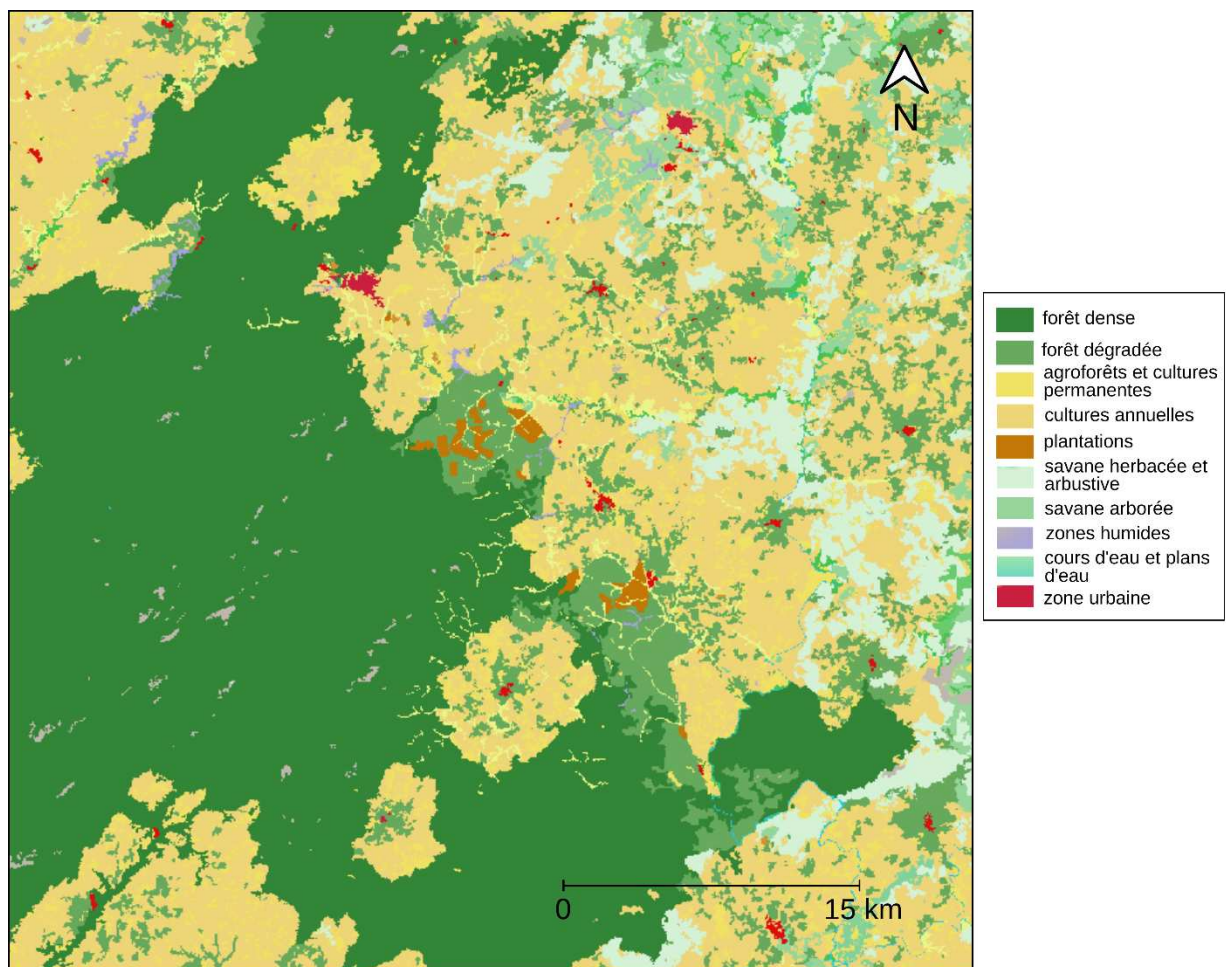


Figure 6 : Carte 2015 de l'occupation des sols (OCS) de la zone d'étude de Ziama. Source : projet ZAEG.

<sup>9</sup> <https://whc.unesco.org/fr/soc/1744>

Notre zone d'étude principale est une des 5 zones pilotes du projet ZAEG décrit en section 2.2 (9°17'12.75"O, 8°22'18.91"N) et se situe au sein de la forêt de Ziama (fig. 6). Ce massif forestier a été classé en 1942, puis déclaré comme réserve de Biosphère le 17 février 1981. Sa superficie totale est de 116 700 ha, dont 42 547 ha désignés comme zone centrale (zone montagneuse) où l'extraction du bois et la chasse sont prohibées, 27 233 ha de zone tampon et 46 390 ha comme « aire de transition » ou zone à usages multiples qui comprend une concession forestière de 30 000 ha<sup>10</sup>. La forêt est de **type dense sempervirente ou semi caducifoliée**. Il existe deux étages de végétation : l'étage inférieur aux altitudes proches de 950 à 1 000 mètres, et l'étage montagnard surplombant le précédent (jusqu'à 1 400 mètres). Les principaux habitats sont la forêt de montagne primaire (espèces dominantes : *Lophira alata*, *Heritiera utilis*, et *Morus mesozygia*), la forêt de montagne secondaire (*Pipadeniastrum africanum*, *Lengué*, et *Canarium schweinfurthii*), la forêt secondaire dans les vallées, les plaines et les marécages et enfin la savane.

Cette forêt protège la dernière population viable d'éléphants de forêt en Guinée et, conjointement avec la forêt de Diécké la dernière d'hippopotames pygmées (*Hexaprotodon liberiensis*) (UICN 2008). La forêt du Ziama abrite aussi 133 espèces de mammifères (dont 50 espèces de grands mammifères). En 2001, un exercice de priorisation régionale des zones à forte valeur biologique au sein de la région forestière s'étendant de la Guinée au Togo a d'ailleurs identifié la forêt du Ziama comme une des zones les plus importantes pour la préservation de la biodiversité de la région. A noter aussi que Ziama est également classée comme une zone d'importance pour la conservation des oiseaux (ZICO, ou « Important Bird Area », IBA, en anglais) où plus de 287 espèces ont été dénombrées.

## 2.2. Etat des lieux : le projet Zonage Agro-Écologique de Guinée (ZAEG)

La problématique de détection des forêts dégradées a émergé dans le cadre du projet de Zonage agro-écologique de la Guinée (ZAEG), qui comprend la cartographie de l'occupation du sol et de son évolution sur 10 ans. Financé par l'AFD (Agence française de développement), le projet ZAEG est porté par IGN FI (société française d'ingénierie cartographique, qui mène des projets de géomatique à l'international) et le Cirad (Centre de coopération internationale en recherche agronomique pour le développement). Le projet ZAEG a montré que les principales menaces pesant sur les massifs de Ziama sont la déforestation et les coupes à blanc pour l'agriculture, les feux et l'extraction du bois. Ces résultats mettent en évidence la nécessité de surveiller le couvert forestier dans les aires protégées de Ziama et Diécké où l'exploitation forestière est interdite.

Dans le projet ZAEG, une carte d'occupation du sol (OCS) de 2015 du territoire guinéen a été créée par des photo-interprètes nationaux sur la base d'une image SPOT-6 du 12/09/2015 pour le ministère guinéen de l'Agriculture. Les cartes des figures 4 à 6 en sont issues. L'image multispectrale SPOT-6 comprend trois canaux visibles et un canal proche infrarouge à une résolution spatiale de 6 m (tableau 1).

---

<sup>10</sup> Evaluation de l'Efficacité de la Gestion des Aires Protégées - IUCN

Tableau 1 : Caractéristiques des bandes spectrales de l'image SPOT-6 du 12/09/2015.

| <b>Bandes spectrales SPOT-6</b> | <b>Longueur d'onde (µm)</b> | <b>Résolution spatiale (m)</b> |
|---------------------------------|-----------------------------|--------------------------------|
| Bande 1 – bleu                  | 0.450 – 0.520               | 6                              |
| Bande 2 - vert                  | 0.530 – 0.590               | 6                              |
| Bande 3 - rouge                 | 0.625 – 0.695               | 6                              |
| Bande 4 – proche infrarouge     | 0.760 – 0.890               | 6                              |
| Bande 5 - panchromatique        | 0.450 – 0.745               | 1.5                            |

La carte OCS a été produite de manière semi-automatique par classification supervisée Random Forest après sélection de régions d'intérêt sur les images satellites, et à l'aide d'imagerie à très haute résolution spatiale accessible via les plateformes Google Earth Pro et Bing Aerial. La première étape de classification supervisée en 10 classes a été appliquée sur l'image SPOT-6, et s'est suivie d'une deuxième étape d'attribution de 30 classes plus précises et plus complexes, étape qui a été réalisée de façon manuelle sur chaque polygone.

Les forêts dégradées n'ont pas pu être détectées automatiquement à partir de l'image SPOT-6 et les photo-interprètes ont dû remplir tous les polygones un par un, en utilisant le contexte et des images à très haute résolution comme Google Earth, Bing Aerial et l'image SPOT-6 pansharpened à 1,5 m de résolution spatiale. L'interprétation visuelle prend en compte la structure et la physionomie du peuplement forestier ainsi que les éléments secondaires indicatifs d'un habitat dégradé, cultures, routes, pistes, ruisseaux, etc. Bien que cette procédure soit robuste et complète, la numérisation manuelle des zones dégradées est particulièrement chronophage. Quarante-deux classes ont été considérées au total sur la Guinée. La nomenclature des classes est basée sur le concept de couverture terrestre de Corine Land Cover européen (Heymann et al., 1994) adapté à la région biogéographique guinéenne (Jaffrain G. dans Feranec, 2016). Les résultats du projet ZAEG ont été par ailleurs publiés dans la Revue Française de Photogrammétrie et de Télédétection en 2021 (Jaffrain et al., 2021).

La carte OCS 2020 demandée par le ministère guinéen de l'Agriculture est actuellement à l'étude et sa sortie est prévue pour la fin d'année 2022, basée sur la photo-interprétation des images Sentinel-2. C'est dans le cadre de cette extension de projet que se placent les travaux de thèse sur la détection des forêts dégradées, qui figurent parmi les classes nécessitant une digitalisation manuelle pendant le projet ZAEG<sup>11</sup>.

<sup>11</sup> Les classes nécessitant une digitalisation manuelle incluent les systèmes agroforestiers, les formations arbustives de transition, ou encore les cultures de plaine d'eau douce, les cultures pluviales et jachères, et celles de plaine de mangroves.

### 2.3. Définition des systèmes arborés dans le projet ZAEG

Dans le cadre du projet ZAEG, la **forêt dense** est définie comme une formation d'arbres fermés avec des arbres présentant un couvert supérieur à 70% et une hauteur supérieure à 5 mètres. Leurs cimes sont contiguës et l'ensemble de la canopée reste dense (fig. 7). En Guinée, la forêt dense comprend principalement des forêts sacrées, des forêts ripisylves et des forêts classées, où les formations arborées ne sont pas ou très peu dégradées.

La **forêt dégradée** est identifiée ici, dans le projet ZAEG et dans la thèse, par la formation de forêt d'une hauteur supérieure à 5 mètres et d'une densité de cime supérieure à 30% mais inférieure à 70%, en cours de dégradation (i.e. certains arbres sont prélevés mais la zone conserve suffisamment d'arbres pour être classée comme forêt) ou résultant d'une régénération à un stade forestier (c'est-à-dire que les forêts secondaires sont incluses dans cette classe) selon la définition usuelle en photo-interprétation. Les couronnes de la strate arborescente ne sont plus contiguës, mais les espèces d'arbres de cette strate demeurent les mêmes que celles de la forêt dense (fig. 7).




Figure 7 : illustrations de référence des forêts dense et dégradées dans le guide technique du projet ZAEG. A gauche : forêt dense sur une image SPOT-6 en 2016 (6 m de résolution). A droite : forêt dégradée sur la même image.

La figure 7 montre la difficulté pour les opérateurs de reconnaître parfois les forêts dégradées et les distinguer des forêts denses surtout quand la densité du couvert arboré reste encore importante. Les radiométries et la texture du couvert arboré sont semblables dans les deux types de forêts dans la composition colorée proche infrarouge (PIR)/rouge/vert de SPOT-6, utilisée dans le projet ZAEG. Dans cet exemple, la forêt dégradée a pu être détournée en s'appuyant sur le contexte : la forêt est un fragment subsistant dans un tissu agricole. Le plus souvent, c'est l'imagerie haute résolution accessible via Google Earth qui permet d'identifier les forêts dégradées (fig. 8). Celles-ci présentent une texture plus lisse et les forêts denses une texture plus granuleuse.



Figure 8 : Image Google Earth (9°15'32.41"O, 8°10'49.72"N). Forêt dense (carré B) et forêt dégradée (carré A).

Les **systèmes agroforestiers** sont pris en compte dans l'analyse, car ils sont confondus avec la classe de forêt dégradées dans les images satellites ; pour la production de la carte ZAEG, ils n'ont pu être identifiés que grâce aux visites terrain. Selon la FAO, l'agroforesterie désigne les systèmes d'utilisation des terres et les pratiques dans lesquelles les plantes ligneuses vivaces sont délibérément intégrées aux cultures agricoles et / ou à l'élevage. En Guinée, cette forme d'utilisation des terres associe des espèces forestières et des espèces fruitières locales dans des systèmes multi-étagés. Mais les agroforêts se développent au détriment des forêts et des zones de cultures vivrières et leur évolution remet en cause la durabilité des pratiques agricoles en Guinée (Camara et al., 2009). En effet, l'exploitation croissante du bois d'œuvre de ces agroforêts réduit leur complexité structurelle et floristique, et les conséquences en termes économiques et environnementaux en restent à évaluer. Ici, il s'agit de plantations de caféiers, manguiers, anacardiens, orangers et avocatiers se trouvant sous le couvert arboré, souvent très épars et dominé par des palmiers à huile ; ils ne sont pas perceptibles par satellite en raison de l'étage supérieur. Ici, les systèmes agroforestiers sont généralement de petits résidus forestiers entourés de vastes étendues agricoles et/ou des villages environnants (fig. 9).




Figure 9 : agroforêts (orange). Compositions colorées Sentinel-2 (PIR/MIR/R).

Enfin, les **forêts de plantation** sont une autre forme de couverture arborée répandue dans la région, mais sont distinguées des forêts denses. Les forêts de plantation sont définies par la FAO comme des forêts gérées de manière intensive, composées d'une ou deux espèces, équiennes, plantées à intervalles réguliers et établies principalement à des fins productives, qui ne sont pas susceptibles d'être durables à long terme. Les plantations d'arbres en Guinée sont des monocultures d'hévéas à croissance rapide (fig. 10). En général, les plantations d'arbres à espèce unique drainent les nutriments du sol plus rapidement et renvoient moins de nutriments au sol que la forêt indigène et la végétation de savane (Aweto, 2009).



Figure 10 : plantations d'hévéas (rouge foncé). Compositions colorées Sentinel-2 (PIR/MIR/R).

## 2.4. Données de terrain collectées durant la thèse

Dans le projet ZAEG, les forêts dégradées n'ont pas pu être détectées par classification automatique de l'image SPOT-6 et la section 2.3 montre la difficulté parfois pour les opérateurs de reconnaître les forêts dégradées et les distinguer des forêts denses sur l'image SPOT-6. Nous supposons que l'étude d'une image satellite à date unique ne permet pas d'identifier clairement la dégradation des forêts dans la mesure où elle est graduelle et progressive dans le temps et dans l'espace. Les changements ténus d'une forêt dense à une forêt dégradée peuvent être manqués car ils nécessitent plus d'attention et d'analyse de l'image sur plusieurs dates pour exclure l'effet saisonnier. L'identification des forêts dégradées doit également être soutenue par la connaissance du terrain et des pratiques locales.

C'est pourquoi des incertitudes de la classe de forêts dégradées sont observées dans la carte ZAEG, dont un exemple est donné dans la figure 11. Bien que classée comme forêt dense dans le projet ZAEG, la forêt à l'interface entre les cultures de bas-fond et celle de massif montre des signes de dégradation (fig. 11). La texture est plus lisse et les radiométries plus faibles sur la composition colorée PIR/rouge/vert de l'image SPOT-6.

C'est dans ce contexte que des données de terrain ont été collectées pour la thèse dans ces forêts d'interface<sup>12</sup>. Ces données de terrain ont pour objectif : i) de tester la précision thématique de la carte OCS 2015 du projet ZAEG, ii) de relever les espèces dominantes dans les forêts denses et les forêts dégradées avérées, et iii) de tester un indicateur quantitatif d'ouverture de la canopée.

---

<sup>12</sup> La campagne de terrain a pu être menée à bien grâce à la disponibilité et à l'accueil que m'ont réservé Mory Esdras Haba, Sékou Touré, Maxime et Arthur Leroux.




Figure 11 : incertitudes de la classe forêt dégradée observées dans la carte ZAEG (en haut). La carte ZAEG 2015 présente des défauts sur la classe de forêt dégradée, qui est faiblement visible sur l'image SPOT6 (au milieu). En bas, photographie de l'interface forêt/non-forêt (étoile verte), Ziama le 25 avril 2019. Source : An Vo Quang.



### 2.4.1 Transects

Nous avons effectué le travail de terrain dans le massif protégé de Ziama (8°14'22.2 "N, 9°21'44.0 "W) pendant la saison sèche en avril 2019. Les enquêtes de terrain ont été réalisées sur 4 transects, près de la ville de Sereidou (fig. 13). La longueur des transects varie entre 400 mètres et 1,1 kilomètre selon l'épaisseur de l'ourlet forestier. Les relevés au sol ont été collectés tous les ~100 mètres dans chaque transect, en partant de l'interface forêt/non-forêt et en continuant à l'intérieur du massif forestier, totalisant 66 points collectés. Les points d'échantillonnage ont été géoréférencés à l'aide d'une tablette GPS (précision de  $\pm 5$  m). La liste de paramètres de chaque relevé est donnée dans le tableau 2.

Les transects sont tous situés dans des forêts classées denses dans la carte ZAEG, mais dont des incertitudes sur l'état dégradé ont été observées sur les images SPOT6 et très haute résolution Google Earth (fig. 11). Ils sont divisés en trois parties pour l'étude des séries temporelles dans le chapitre 3 :

- (i) La partie anthropisée est la partie la plus proche de la zone anthropisée (cultures, routes, surfaces ouvertes) (triangles roses dans la figure 13) ;
- (ii) La partie intermédiaire, qui demeure dégradée (triangles jaunes) ;
- (iii) La partie « massif » du transect (indiquée par les triangles verts).

Les coordonnées géographiques, la classe d'utilisation du sol (forêt dense ou forêt dégradée) expertisée par l'agent forestier, des photographies hémisphériques, les espèces dominantes et la présence d'espèces pionnières (sur un périmètre visuel de 10 m) ont été répertoriées sur chaque point de relevé (fig. 12).



Figure 12 : collecte des données terrain, forêt de Ziama (photographie prise le 25 avril 2019).

Tableau 2 : relevés terrain de la campagne avril 2019.

|     |  |
|-----|--|
| 1.  | ID (identifiant), n° de transect   |
| 2.  | Coordonnées géographiques  |
| 3.  | Date du relevé   |
| 4.  | Occupation du sol : forêt dense, forêt dégradée                                    |
| 5.  | Si forêt dégradée : forêt en régénération (secondaire) (oui/non)                   |
| 6.  | Espèces dominantes dans un périmètre visuel de 5 m                                 |
| 7.  | Présence d'espèce(s) pionnière(s) adaptées à ces microclimat (oui/non, lesquelles) |
| 8.  | Résidus de cultures (oui/non, lesquelles)  |
| 9.  | Pratiques de défrichement ou déboisement (oui/non)                                 |
| 10. | Photographies hémisphériques pour la mesure de la fraction de trou                 |

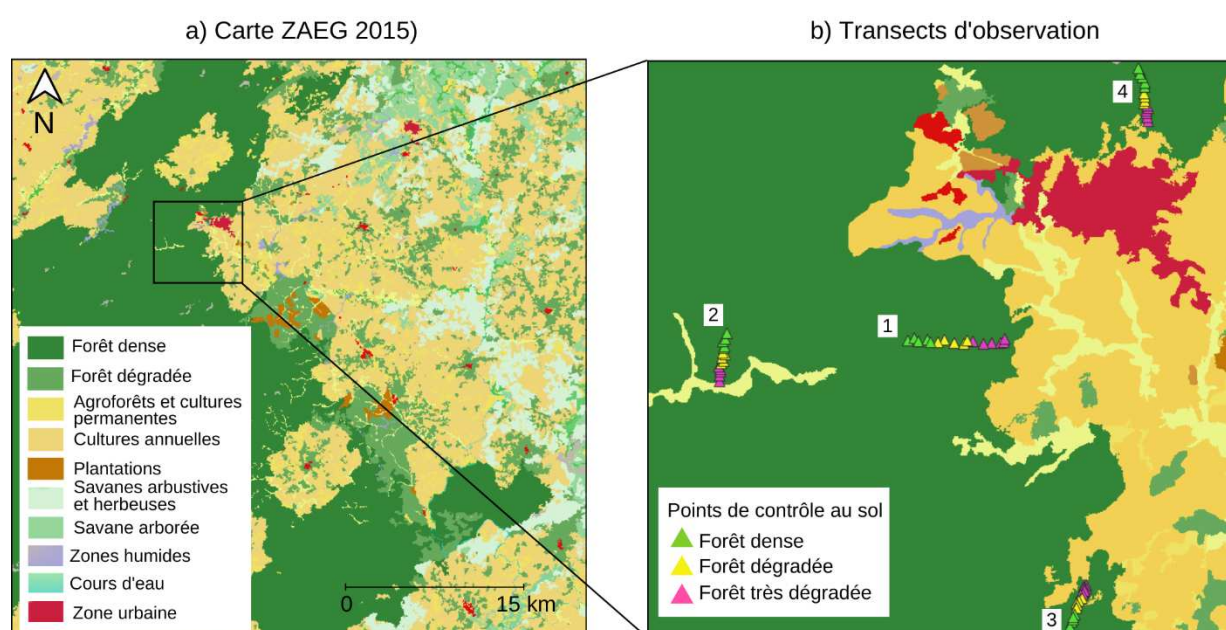


Figure 13 : a) Carte ZAEF de 2015 de la zone d'étude dans le massif de Ziama, à partir de l'image SPOT-6 12/09/2015 ; b) enquêtes de terrain réalisées sur les 4 transects. Les points de contrôle au sol dans les transects sont représentés par des triangles. L'analyse est affinée sur les pixels dans les transects (vert : forêt dense ; jaune : forêt dégradée ; rose : forêt sévèrement dégradée).

Afin de statuer sur l'état dégradé ou non dégradé du peuplement, le garde forestier se base sur la composition des espèces d'arbres (2.4.2), la présence de lianes (voir plus bas), sur les traces d'exploitation forestière et sur les traces laissées par la chasse (pièges pour petits mammifères etc.) (fig. 14). De nombreuses traces de récolte de produits forestiers non ligneux ont été trouvées dans les parties dégradées de la forêt (palmiers *Elaeis guineensis*, poivre, avocats *Persea americana*, rotin *Angyrostrophyllum scecondiflorum* et *Eremospatha macrocarpa* utilisés pour le mobilier). La récolte des

produits forestiers non ligneux fait partie du droit d'usage des communautés locales, mais des traces de pièges et de braconnage montrent un passage fréquent des villageois, ce qui peut être considéré comme des causes supplémentaires de dégradation (fig. 15 et 16).

Des processus simultanés de régénération forestière et de perturbation répétée (coupe de bois, incendies, culture...) ont été observés dans les forêts dégradées inspectées, ce qui montre la difficulté de quantifier l'étendue de la dégradation et de catégoriser les forêts dégradées.



Figure 14 : piège pour petits mammifères, forêt de Ziama (25 avril 2019).



Figure 15 : fruits du palmier *Elaeis guineensis* trouvés en forêt dégradée. Photographies prises le 26 avril 2019.



Figure 16 : fruits du palmier *Elaeis guineensis* avant transformation (gauche) puis transformés en huile de palme (droite), en bordure de forêt, Ziama (26 avril 2019). Source : An Vo Quang.

#### 2.4.2. Relevés floristiques

Les observations au sol ont révélé des différences structurelles dans les forêts dégradées par rapport aux forêts denses dû à l'exploitation sélective. La biodiversité parmi les arbres matures était plus élevée dans les forêts denses, où l'on rencontre plusieurs espèces de la liste rouge de l'UICN (*Milicia regia*, *Milicia excelsa*, *Combretodendrons africanum*, *Entondrophragma candollei*, *Antonotha fragrans*). Les témoignages des gardes forestiers locaux suggèrent que la coupe sélective est effectuée de préférence sur des arbres plus vieux et plus grands ayant une plus grande valeur commerciale, généralement inscrits dans la liste rouge de l'UICN. La coupe de grands arbres matures dans les forêts dégradées entraîne une prédominance d'arbres plus minces avec des couronnes moins denses.

La campagne de terrain dans la forêt dégradée révèle la présence de trouées dans la canopée supérieure, créées par les coupes sélectives (Fig. 13) qui conduit à de nouvelles conditions environnementales plus lumineuses conduisant à l'infestation de lianes (*Scleria barteri*, *Culcasia scandens*, *Platycerium angolens*, *Dalbergia*, *Entada*, *Phyllanthus muellerianus*, *Sherbournia bignoniiflora*, *Dioscorea minutiflora*, *Paullinia pinnata*) (fig. 17 et 18) et à l'émergence d'espèces héliophiles pionnières telles que les palmiers *Elaeis guineensis*.



Figure 17 : lianes en forêt dégradée (photographie prise le 26 avril 2019).



Figure 18 : présence de trouées dans la canopée supérieure et lianes en forêt dégradée (photographies prises le 26 avril 2019).

Les observations de terrain sur les différences structurelles entre forêts denses et forêts dégradées sont synthétisées en figure 19. Un transect y est schématisé de la partie anthropisée vers la partie massif.




Figure 19 : schéma d'un transect d'observation de forêt d'interface.

Les lianes semblent avoir des préférences d'habitat pour les forêts perturbées à haute disponibilité en lumière, alors qu'elles sont à peine présentes dans les forêts denses non perturbées. Leur forte abondance serait une résultant de la dégradation.

Ceci est corroboré par la littérature. Les études sur la dynamique de la couverture de lianes en milieu tropical indiquent des taux élevés d'infestation d'arbres dans de nombreuses régions tropicales (Putz, 1983, 184 ; Alvira et al., 2004 ; Pérez-Salicrup et al., 2001 ; Pérez-Salicrup & de Meijere, 2005). La dominance croissante des lianes dans de nombreuses forêts tropicales est considérée comme le résultat de la combinaison du changement climatique global dans les pays tropicaux et de l'intensification des pressions d'origine anthropique liées à l'exploitation du bois (van der Heijden et al., 2013 ; Phillips et al., 2002). La végétation de sous-bois est généralement sciaphile dans les forêts tropicales denses et l'ouverture de la canopée entraînerait un changement dans la composition des espèces végétales. Les lianes montreraient une plus grande efficacité à capturer l'eau et les nutriments que les arbres hôtes (Schnitzer, 2002 ; Schnitzer, 2005 ; Sanchez Azofoifa et al., 2009) dans des conditions environnementales de stress hydrique et de plus grande disponibilité de lumière (fig. 19). Les lianes utilisent également les arbres comme supports verticaux pour grimper jusqu'aux interstices de la canopée et bénéficier d'un meilleur ensoleillement, comme cela a été observé sur l'île de Barro Colorado (Panama) où l'on a constaté que la richesse en lianes était significativement plus élevée dans les sites avec des trouées dans la canopée que dans les sites sans trouées (Schnitzer et al., 2005, 2012).

D'autres études montrent que les lianes entravent la régénération des arbres et augmentent leur mortalité (Schnitzer et Carson, 2010), ce qui entraîne une boucle de dégradation auto-entretenu dans les forêts vulnérables (Pérez-Salicrup et Barker, 2000). Une infestation sévère de lianes réduirait la croissance des arbres et augmenterait leur mortalité en entrant directement en compétition avec les arbres, mais aussi

en affectant la diversité des espèces d'arbres et en modifiant ainsi la manière dont les arbres entrent en compétition. En se basant sur une base de données pantropicale, Duran & Gianoli, (2013) ont montré que l'abondance en lianes impacte négativement les stocks de carbone des arbres de plus de 10 cm de diamètre.

En résumé, leur plus grande efficacité à capter l'eau et les nutriments que les arbres hôtes (Schnitzer, 2005) dans des conditions environnementales de stress hydrique et de plus grande disponibilité de lumière, peut expliquer en partie l'expansion des lianes dans les forêts tropicales ces dernières années. Cet avantage se combine la capacité des lianes à entraver la croissance des arbres. Ainsi, la présence de lianes est retenue comme l'un des indicateurs pour décider de l'état dégradé ou non d'une forêt lors des observations de terrain, au côté de la fermeture de la canopée de la strate supérieure et des traces au sol de l'exploitation des ressources.

### 2.4.3. Relevés de mesure de l'indice de surface végétale (PAI)

Pour caractériser la structure de la canopée, une mesure couramment utilisée est l'indice de surface végétale (plant area index ou PAI) pour quantifier la surface des éléments interceptant la lumière dans les canopées, qui comprennent les branches ainsi que les feuilles.

Pour cela, la photographie numérique est une méthode non destructive, utilisée depuis les années 1970 pour mesurer le PAI et l'indice de fraction de trou qui est le degré d'ouverture de la canopée. En particulier, la photographie hémisphérique numérique (aussi connue sous le nom de photographie *fisheye*) présente de nombreux avantages : un temps de traitement et un coût financier moindres, une grande facilité de mise en place dans l'enregistrement des informations sur la canopée. La photographie hémisphérique numérique a largement été utilisée pour de nombreux types de canopées, allant de grands arbres aux petits arbustes, de mangroves, de végétation inondée, aux couverts herbacés (Zhao et al., 2014 ; Chianucci et Cutini, 2013 ; Garrigues et al., 2008 ; Gonsamo et Pellikka, 2009 ; Liu et Pattey, 2010).

Les photographies sont réalisées à l'aide d'un appareil photographique équipé d'un objectif *fisheye* circulaire avec un angle de vue diagonal de 180° environ. Dirigées vers le haut, les photographies hémisphériques ont été prises sous la canopée des arbres à l'aide d'un trépied de 60 cm. La **fraction de trou** (ou taux d'ouverture de la canopée) est calculée à partir d'une image binaire issue de la photographie où chaque pixel est classé en « trou » ou « végétation ». Pour s'assurer que l'appareil photographique est à l'horizontale, des niveaux à bulle sont fixés à l'appareil côté objectif et à l'extrémité opposé du trépied. Avant de prendre des photographies, les bulles sont nivelées simultanément.

Au minimum, 20 photographies hémisphériques ont été prises par point pour rendre une représentation de la canopée plus réaliste, en raison de la petite couverture de chaque photo (Weiss et al., 2004). Les photographies ont été séparées en deux catégories « forêts intactes » et « forêts dégradées » (fig. 20). La fraction de trou a ensuite été calculée à partir de l'image binaire « végétation » / « ciel » (Garrigues et al., 2008 ; Weiss et al., 2004).




Figure 20 : photographies hémisphériques dans une forêt dense (série 1, en haut) et une forêt dégradée (série 2, en bas). Dans cette dernière, les trouées de la canopée, créées par la chute d'arbres et les coupes sélectives, conduisent à de nouvelles conditions environnementales de plus grande disponibilité de la lumière (2a), entraînant la colonisation des lianes (2b) et l'émergence d'espèces héliophiles pionnières comme les palmiers *Elaeis guinensis* (2c). Dans une forêt dense sans trace de perturbation, très peu de lumière solaire traverse la canopée (1a, 1b et 1c). Photos prises dans le massif du Ziama (8°14'22« 2 "N, 9°21'44« 0 "W) le 21 avril 2019.

Le transect 1 montre un degré d'ouverture de sa canopée qui diminue à mesure lorsque les relevés se trouvent en forêt dense (numéros de relevé de terrain les plus élevés), comme attendu. En revanche, les transects 2, 3 et 4 montrent des fractions de trou qui diminuent dans les forêts dégradées mais indiquent des fractions de trou plus élevées en forêt dense en fin de transect (fig. 21). Ce résultat est expliqué par le fait que les transects 3 et 4 se trouvent en forêt en affleurement rocheux : la forêt dense est donc à flanc de montagne et est naturellement plus ouverte au niveau de sa canopée par les eaux de ruissellement. Le transect 2 s'est terminé en zone de bas-fond, dont la canopée de la forêt dense marécageuse est plus ouverte.



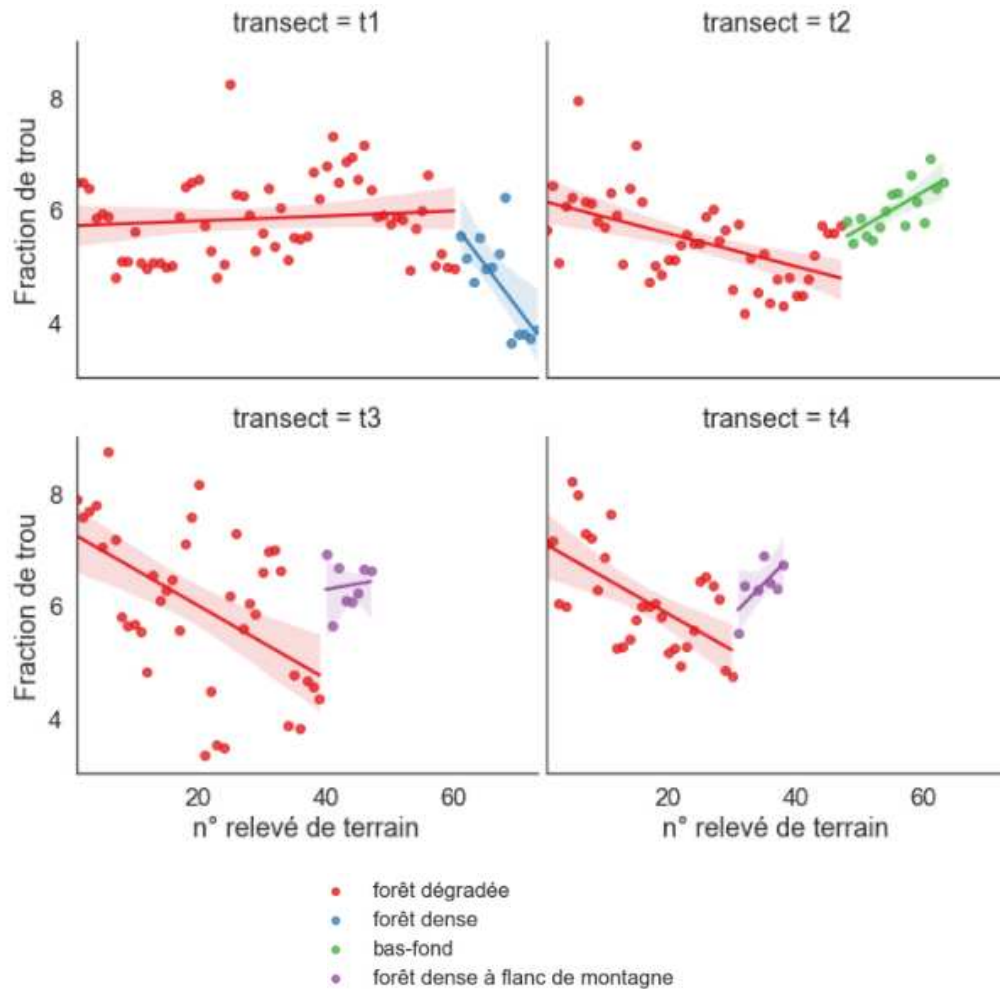


Figure 21 : Fraction de trou (« gap fraction ») sur chaque relevé de terrain dans les 4 transects. Le départ de chaque transect (relevé n°1) se situe aux lisières de forêt.

Les mesures de la fraction de trou à partir des photographies hémisphériques ne se sont pas révélées pertinentes en forêt tropicale guinéenne dû :

1. à la fermeture rapide du feuillage pendant la régénération secondaire, induisent des biais dans le degré d'ouverture de la canopée et sa mesure dans notre zone d'étude ;
2. à l'appréciation de la hauteur des strates qui est différente sur le terrain de ce qu'on voit par satellite, particulièrement dans les forêts dégradées. Comme les lianes y sont très abondantes, mais absentes dans les forêts denses, la perception de la densité est biaisée vue du sol. L'étage inférieur peut être particulièrement dense chez les forêts dégradées dû aux lianes, mais la canopée i.e. l'étage supérieur très ouvert par l'absence de gros arbres âgés (fig. 22).




Figure 22 : schéma des différences structurelles observées entre les forêts denses et les forêts dégradées sur le terrain en Guinée forestière. La composition de la forêt est modifiée dû à l'exploitation sélective : l'abondance en espèces commerciales diminue tandis que celle des espèces secondaires dans les trouées d'exploitation augmente.

En conclusion, la fraction de trouée n'a pas été employée comme indicateur quantitatif de la dégradation forestière. Les photographies hémisphériques ont servi de références qualitatives sur la composition des espèces et la structure de la canopée.

#### 2.4.4. Conclusions des observations de terrain

Les points de contrôle au sol collectés pour tester la précision thématique de la carte ZAEG, notamment dans les zones forestières de bordure, ont été classés comme "forêt dense" dans la carte ZAEG, mais les forestiers locaux ont évalué ces peuplements comme dégradés. Ce conflit a été rencontré dans les quatre transects et montre que la photo-interprétation telle qu'elle est utilisée dans la carte ZAEG de 2015 peut être délicate pour la détection de la forêt dégradée.

Au-delà de cette évaluation de la carte ZAEG, la campagne d'observations de terrain a aussi permis d'identifier deux types de trajectoires possibles pour les forêts guinéennes soumises à la pression anthropique. En Guinée forestière, la pression des activités humaines s'intensifie avec la récolte des arbres fruitiers et des caféiers. Les observations locales et les témoignages des gardes forestiers locaux indiquent que la plupart des formations dégradées évoluent en systèmes agroforestiers, avec des espèces fruitières cultivées associées comme les palmiers, les avocats, les manguiers, les cacaoyers, les caféiers (fig. 23).

Ceci diffère partiellement des conclusions de Vancutsem et al. (2021) selon lesquels, à l'échelle pantropicale, la dégradation est dans environ 45% des cas suivie d'une déforestation.




Figure 23 : Processus de dégradation basé sur les observations de terrain de Ziama et les témoignages des gardes forestiers locaux.

## 2.5. Amélioration de l'interprétation visuelle des forêts dégradées et création d'un jeu de données de référence

Dans le projet ZAEG, les photo-interprètes ont numérisé les forêts dégradées puis renseigné tous les polygones un par un. La photo-interprétation des classes s'est appuyée sur le contexte entourant les forêts établi sur la base des images très haute résolution issues de Google Earth, Bing Aerial et l'image SPOT-6 pansharpened. Bien que cette procédure soit robuste et approfondie, les données de terrain de la section 2.4 montre les limites de l'interprétation visuelle mono-date utilisée dans le projet ZAEG. L'utilisation de l'imagerie Sentinel-2 (S2) pour la mise à jour 2020 de la carte ZAEG pourrait être plus adaptée, par sa plus large gamme spectrale et sa haute résolution temporelle.

### 2.5.1. Données satellitaires

En 2015, le lancement des missions Sentinel-2 (capteurs optiques) du programme Copernicus de l'Agence Spatiale Européenne (ESA) a permis de combiner haute résolution spatiale et forte fréquence temporelle d'observations, offrant de nouvelles opportunités pour la cartographie et le suivi de la couverture et de la biomasse forestière terrestre, en particulier dans les tropiques où la déforestation est la plus élevée.

Sentinel-2 propose 13 bandes multispectrales allant de 440 nm à 2200 nm (Tableau 3). Les données acquises associent résolution spatiale fine (~ 10 m) avec une résolution temporelle inégalée jusqu'alors (6 jours en Europe, 12 sur le continent africain en utilisant les 2 satellites Sentinel-2A et 2B), et une fauchée de 250 km permettant de travailler à une échelle régionale. Elles sont distribuées librement pour tout utilisateur sur le portail de l'ESA (<https://scihub.copernicus.eu/dhus/#/home>).

Tableau 3 : Caractéristiques des bandes spectrales de Sentinel-2. Les bandes 2 à 8A, 11 et 12 ont été utilisées pour cette étude (surlignées en gris).

| Sentinel-2 bands                              | Longueur d'onde centrale (µm) | Résolution spatiale (m) |
|---|-------------------------------|-------------------------|
| Bande 1 – aérosols                            | 0.443                         | 60                      |
| Bande 2 – bleu                                | 0.496                         | 10                      |
| Bande 3 – vert                                | 0.560                         | 10                      |
| Bande 4 – rouge                               | 0.665                         | 10                      |
| Bande 5 – végétation 'red edge' 1             | 0.704                         | 20                      |
| Bande 6 – végétation 'red edge' 2             | 0.740                         | 20                      |
| Bande 7 – végétation 'red edge' 3             | 0.783                         | 20                      |
| Bande 8 – proche infrarouge (PIR) « large »   | 0.834                         | 10                      |
| Bande 8A – proche infrarouge (PIR) « étroit » | 0.865                         | 20                      |
| Bande 9 – vapeur d'eau                        | 0.945                         | 60                      |
| Bande 10 – cirrus                             | 1.375                         | 60                      |
| Bande 11 – moyen infrarouge (MIR) 1           | 1.610                         | 20                      |
| Bande 12 – moyen infrarouge (MIR) 2           | 2.190                         | 20                      |

La compréhension du terrain et la photo-interprétation sont permises grâce à la haute résolution temporelle de ces images satellites, qui permet d'augmenter la probabilité d'obtenir des images sans nuage. Les emprises des images Sentinel-2 sur les 3 massifs forestiers sont illustrées en vert dans la figure 24. Ziama et Nimba sont entièrement englobés dans une emprise, tandis que Diécké requiert un mosaïquage de deux emprises.




Figure 24 : Les emprises des images Sentinel-2 sur la Guinée Forestière (en vert) et le reste de la Guinée (en bleu). Les massifs forestiers de Ziama, Diécké et Nimba sont indiqués en rouge.

Dans ce travail de thèse, nous nous sommes attachés à évaluer le potentiel des séries temporelles Sentinel-2 pour la cartographie des forêts dégradées. Les données Sentinel-2 de niveau L1C ont été acquises auprès du Copernicus Open Access Hub et la sélection des images a été basée sur des critères de faible couverture nuageuse (<5%) et effectuée de décembre à février pendant la saison sèche pour la comparabilité des données. 23 images ont été sélectionnées entre fin 2015 et 2020 pour :

- 1) L'analyse temporelle des propriétés radiométriques des couverts forestiers en fonction de leur état de dégradation, et
- 2) La production de cartes annuelles OCS par la photo-interprétation,
- 3) La classification d'image pour la mise à jour de la carte d'occupation des sols de 2020.

Parmi elles, une image a été retenue pour chaque année de 2015 à 2020, si possible fin janvier/début février pour la comparabilité des données. La photo-interprétation et l'étiquetage des pixels ont ensuite été réalisés sur chaque image annuelle (voir section 2.5.2) pour produire des cartes annuelles de forêts dégradées (tableau 4). Utilisées comme cartes de référence, elles permettront l'entraînement des modèles et la validation des tests de classification aux chapitres suivants.

Tableau 4 : Images Sentinel-2 utilisées dans cette étude sur Ziama. 23 images acquises entre fin 2015 et 2020 ont été utilisées pour 1) l'analyse temporelle des changements radiométriques du couvert forestier, sur une petite fenêtre d'acquisition de décembre à février en saison sèche, permettant la comparabilité des données, et pour la production de cartes de forêts dégradées par les méthodes semi-automatiques développées aux chapitres 3 et 4 ; 2) une image a été conservée pour chaque année et une photo-interprétation a été réalisée pour produire des cartes de forêt dégradée de référence annuelle.

| Date d'acquisition des images Sentinel-2 avec moins de 10% de nuages |                       | Date utilisée pour produire les cartes de référence annuelles par photo-interprétation |
|--|-----------------------|--|
| 2015   | 3 décembre            | 3 décembre 2015  |
| 2016   | 27 décembre           | -  |
| 2017   | 16, 26 janvier        | -  |
|  | 5 février             | 5 février 2017   |
|  | 17 décembre           | -  |
| 2018   | 1, 6, 11, 21 janvier  | -  |
|  | 10 février            | 10 février 2018  |
|  | 17, 27 décembre       | -  |
| 2019   | 1, 11, 21 janvier     | 21 janvier 2019  |
|  | 22 décembre           | -  |
| 2020   | 6, 11, 16, 21 janvier | -  |
|  | 5, 15 février         | 5 février 2020   |

### 2.5.2. Méthodes

Les images Sentinel-2 ont servi notamment pour la construction d'un jeu de données de référence nécessaire pour les modèles d'apprentissage supervisé décrits aux chapitres suivants, tant pour l'entraînement que pour la validation. Le jeu de données de référence a été construit par photo-interprétation selon les méthodes habituelles dans les projets OCS.

En amont de l'étape de photo-interprétation, les 10 bandes spectrales Sentinel-2 utilisées pour la thèse (bandes 2 à 8A, 11 et 12) ont été rééchantillonnées à 10 mètres à l'aide du logiciel Sentinel-2 ToolBox développé par l'ESA et géoréférencées dans le système géodésique WGS84 avec projection UTM, zone 29.

La numérisation et l'étiquetage des pixels par photo-interprétation des données S2 se sont appuyés sur des imageries de très haute résolution Google Earth et/ou Bing Aerial lorsque les dates étaient cohérentes. Les données à très haute résolution aident à distinguer les formations végétales dominantes (savanes arbustives, savanes herbeuses, forêts dégradées, systèmes agroforestiers, etc.) et à valider les classes.

La réflectance de la végétation dans la région du moyen infrarouge (MIR, bandes 11 et 12 de Sentinel-2, ou encore la bande 5 de Landsat TM et la bande 4 des capteurs SPOT 4) varie en fonction des types de plantes et de leur teneur en eau. La réflectance des feuilles augmente généralement dans la région MIR lorsque la teneur en eau liquide des feuilles diminue. Cette propriété peut être utilisée pour identifier les conditions des plantes à partir d'images de télédétection. Cependant, l'absence de bande MIR sur SPOT 6 et 7 ne permet pas cette approche sur les données SPOT récentes (fig. 25).




Figure 25 : comparaison des compositions colorées utilisées pour photo-interpréter les forêts dégradées sur SPOT6 (PIR/rouge/vert) dans le projet ZAEG et celle proposée pour Sentinel-2 (PIR/MIR/rouge) en 2015 (gauche). La photo-interprétation sur Sentinel-2 est facilitée par l'examen d'images Sentinel-2 à d'autres dates. Exemple pris au point de coordonnées : 9°15'32.41"O, 8°10'49.72"N.

Ici, les compositions colorées de Sentinel-2 ont été générées en combinant les bandes proche infrarouge (PIR), MIR1 et rouge dans les canaux rouge, vert et bleu (RGB) respectivement. La séparabilité des classes « forêts dégradées » et « forêt dense » est montrée sur les 3 canaux rouge, MIR1 (bande 11) et PIR (bande 8) pour illustrer le choix de la composition colorée Sentinel-2 utilisée dans la méthode de photo-interprétation de 2015 à 2020 en saison sèche (fig. 26). Pour ce faire, des échantillons des 4 types de forêt (dégradée, agroforestière, plantation d'arbres et forêt dense) sont sélectionnés sur la carte OCS

ZAEG (Fig. 6). Ensuite, comme la carte ZAEG présente des omissions, notamment de non-détection des forêts dégradées, l'analyse est complétée par les pixels appartenant aux transects de terrain afin de bénéficier de l'observation directe des forestiers locaux (transects colorés sur la Fig. 13).

Sur les trois bandes spectrales MIR1, PIR et rouge, on observe une séparabilité des deux classes forestières qui s'atténue en saison humide (fig. 26). On observe une plus grande séparabilité dans le MIR, puis dans le PIR, puis dans le rouge. Les séries temporelles des réflectances Sentinel-2 sont aussi données le canal « vert » (bande 3) car utilisé dans la composition colorée sur SPOT-6 dans le projet ZAEG (PIR, vert et rouge). Dans ce canal, on observe très peu de différence entre les échantillons des couverts arborés ; par conséquent, le canal vert n'est plus envisagé dans les compositions colorées S2. De façon générale, les séries de points des classes forestières se superposent et rendent difficile la discrimination des types de forêts pour la photo-interprétation lorsqu'on exclut la bande MIR de l'analyse.

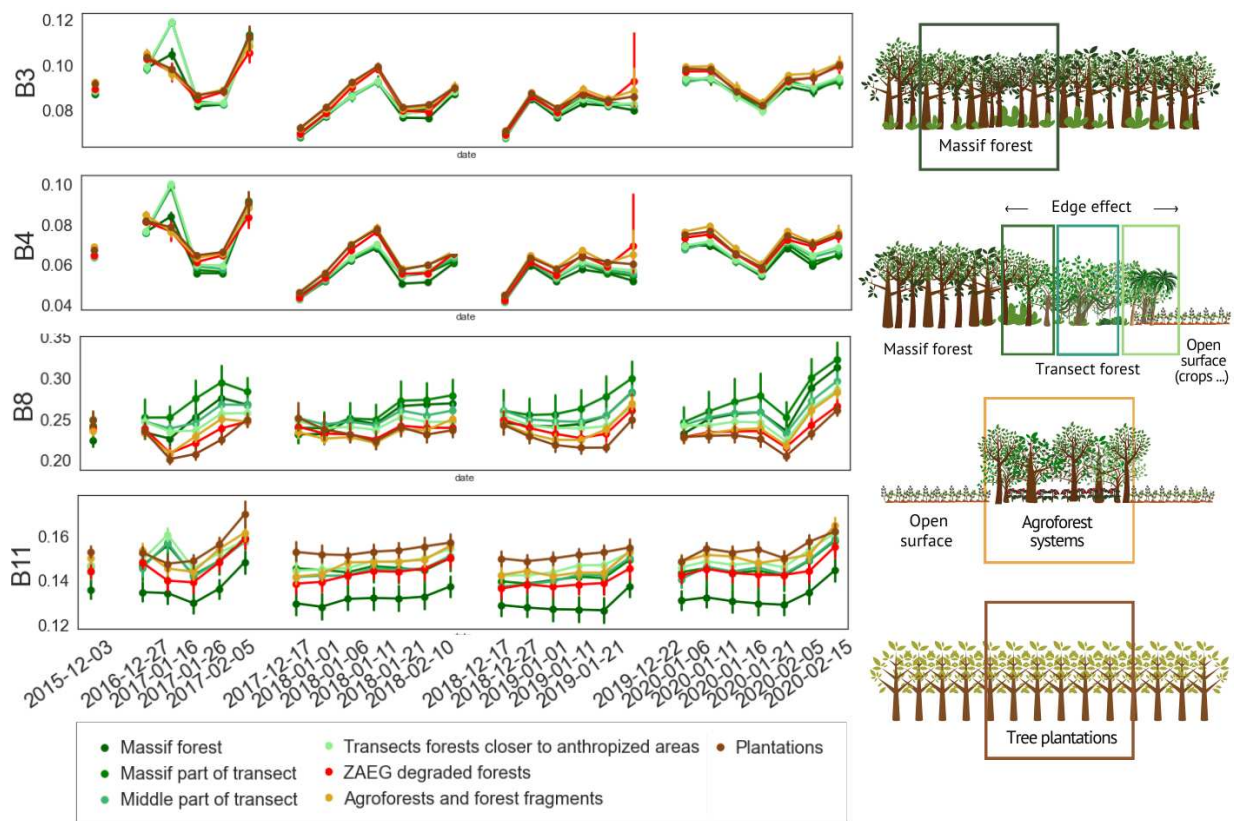


Figure 26 : séries temporelles des réflectances dans les bandes vert (B3), rouge (B4), PIR (B8) et MIR (B11) de Sentinel-2 de 2015 à 2019, en saison sèche, sur des échantillons choisis sur la carte ZAEG (plantations d'arbres en marron, agroforêts en orange, forêts de massif en vert foncé), et à partir d'observations au sol dans des forêts en transect (une partie dans le massif, la 2ème intermédiaire proche du massif, la 3ème proche des zones ouvertes). L'emplacement des pixels est indiqué sur la figure 13.

Sur la base de la composition colorée PIR/MIR/rouge, l'interprétation de l'imagerie Sentinel-2 est réalisée selon les critères suivants :

- i. La texture : une analyse détaillée d'une l'image S2 montre une texture granuleuse plus prononcée dans une forêt dense que pour un type de surface forestière dégradée ;



- ii. La couleur : le MIR est très sensible à la teneur en eau de la canopée, de sorte qu'en plaçant le MIR dans le canal vert de la composition colorée, les forêts dégradées présentent des tons orange et rouge plus « verts » que les forêts denses rouges plus sombres ;
- iii. Le contexte : les conditions de voisinage telles que les routes ou les cultures sont associées à une exposition humaine potentiellement plus élevée, de sorte que les parcelles de forêt sont plus susceptibles d'être dégradées. Le même raisonnement est utilisé pour les parcelles de forêt entourant les villages. Inversement, les forêts situées sur des pentes montagneuses sont moins exposées à l'intrusion humaine. Si les critères de texture et de couleur sont remplis, l'occupation du sol a plus de chances d'être une forêt dense.

Ces critères sont illustrés sur les deux imageries Sentinel-2 en figure 27.




Figure 27 : composition colorée Sentinel-2 générée en combinant les bandes PIR, MIR et rouge dans les canaux rouge, vert et bleu respectivement. La forêt dégradée (A) présente des tons orange et rouge plus « verts » que les forêts denses (B) ; elle se trouve en lisière de terres cultivées et donc plus exposée aux interventions humaines.

L'annotation des classes naturelles par photo-interprétation implique également la compréhension des données géophysiques ou biochimiques des paysages. Par exemple, le contenu chlorophyllien de la végétation les départs de feux d'origine anthropiques, ou encore l'élévation du terrain peuvent modifier les radiométries et être source d'erreur de photo-interprétation. L'identification des classes naturelles est particulièrement difficile dans les images satellites, en raison de la difficulté d'identifier les changements subtils dans les couvertures végétales, en termes de couleurs, de motifs et de tailles d'objets. La connaissance de la dynamique de la végétation, de la variabilité saisonnière et des pratiques locales est obligatoire pour une interprétation rigoureuse. L'analyse des classes naturelles utilise une grande variété d'informations contextuelles telles que le lieu, la saison d'acquisition et le paysage environnant. La contextualisation offre des informations supplémentaires considérables, en particulier pour les classes difficiles comme les forêts dégradées.

Outre les classes « forêt dense » et « forêt dégradée », la classe "autre" qui incluent tous les pixels non forestiers, par exemple les terres cultivées, le tissu urbain, le sol nu, la rivière, la savane herbacée et arbustive, la savane arborée et les plantations d'arbres (fig. 28).




Figure 28 : annotation des classes par photo-interprétation.

### 2.5.3. Création des cartes de forêts dégradées par photo-interprétation

Les cartes photo-interprétées des images S2 acquises en 2015, 2017, 2019 et 2020 sont établies avec la méthode améliorée de photo-interprétation des données Sentinel-2 (fig. 29).

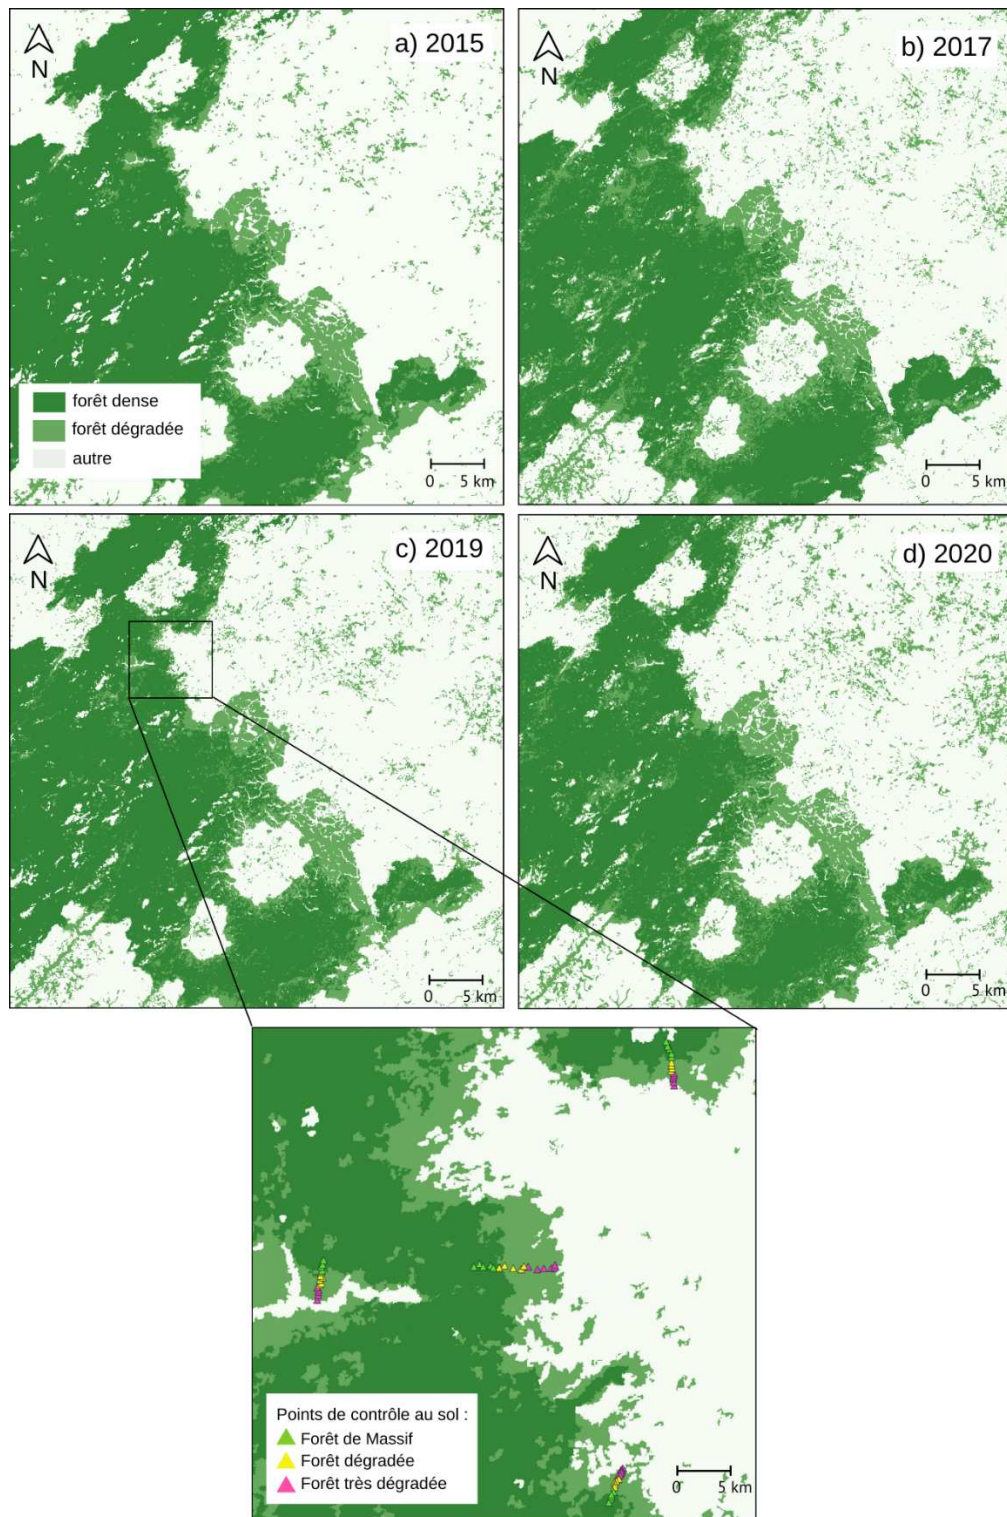


Figure 29 : cartes photo-interprétées des données Sentinel-2 en a) 2015, b) 2017, c) 2019 & d) 2020. L'état de la forêt est celui observé sur le terrain en avril 2019 dans les points de contrôles (triangles).

En particulier, la carte photo-interprétée de l'année 2019 est confrontée aux observations de terrain et aux relevés effectués en avril 2019 (fig. 29). Dans chaque transect, les points d'enquête ont été superposés à la carte photo-interprétée de 2019. Les points les plus proches des terres agricoles et dans la partie centrale du transect (triangles roses et jaunes), et évalués comme dégradés par le forestier local, étaient tous situés dans la classe " forêt dégradée " photo-interprétée, tandis que les points dans la forêt dense (triangles verts) étaient bien situés dans la classe " forêt dense " photo-interprétée.

Cela suggère que les données Sentinel-2 améliorent considérablement la cartographie des forêts dégradées et que la méthode PI adaptée aux données Sentinel peut faciliter la délimitation des forêts dégradées par les opérateurs. Les cartes photo-interprétées permettent par ailleurs d'observer des changements visibles d'une année à l'autre, notamment la présence plus forte des activités humaines à l'intérieur du massif, notables par les îlots de déboisement et la présence de forêts dégradées autour de ces nouvelles interfaces forêt/non-forêt.

## **2.6. Conclusion sur la photo-interprétation des forêts dégradées**

Les résultats de ce chapitre témoignent de l'apport majeur des données Sentinel-2 pour la photo-interprétation des forêts dégradées. D'abord grâce à sa large gamme spectrale qui couvre le moyen infrarouge et qui permet une considérable amélioration de la séparabilité des classes « forêt dense » et « forêt dégradée ». Ensuite, grâce à sa résolution temporelle qui permet de valider l'état de dégradation forestière.

La composition colorée PIR/MIR/rouge appliquée aux images Sentinel-2 donne de meilleurs résultats que celle choisie pour SPOT-6 (PIR/rouge/vert) appliquée aux bandes S2, pour discerner les différences de texture et de couleur. Par leur teinte, les forêts dégradées apparaissent plus facilement grâce au MIR. En considérant le 3<sup>ème</sup> critère lié au contexte (proximité de terres agricoles, routes etc.), la teinte et la granulosité favorisent la digitalisation des forêts pour les opérateurs.

Ensuite, la saison sèche se présente comme la meilleure période d'acquisition d'image Sentinel-2 pour discriminer les forêts dégradées pour sa plus faible nébulosité et car on y observe une séparabilité plus forte des valeurs de radiométries dans les bandes PIR, MIR et rouge dans les mois de décembre à février. Ainsi, la photo-interprétation sur Sentinel-2 a permis d'établir une série de 5 cartes de référence sur 2015, 2017, 2018, 2019 et 2020, toutes photo-interprétées sur 3 classes : forêt dense, forêt dégradée, autre. Ces cartes couvrent le massif de Ziama.

Par la suite, un jeu de données a également été photo-interprété sur le massif de Diécké sur les années 2017, 2019 et 2020, et un dernier jeu de données sur le Mont Nimba en 2021 en vue de valider les modèles de machine learning et de deep learning testés dans les chapitres suivants. Dans les chapitres 3 et 4, ces cartes photo-interprétées permettront d'entraîner et de valider des méthodes de classification supervisée dont l'objectif demeure la cartographie des forêts dégradées.



## Chapitre 3

### Détection semi-automatique des forêts dégradées

Dans ce chapitre, nous cherchons à détecter les forêts dégradées avec une méthode de classification supervisée qui soit i) faible en termes d'effort de photo-interprétation des données, ii) opérationnelle et transférable dans un projet d'OCS. Nous introduisons un état de l'art sur les méthodes de détection des forêts dégradées les plus rencontrées, qui emploient des images optiques, radar ou acquises par drones. La section 3.2 développe plus en détails comment nous introduisons la dimension temporelle dans les méthodes testées. Nous testerons l'une des familles de détection des forêts dégradées les plus utilisées, l'analyse par « démélange spectral » ou SMA (pour *Spectral Mixture Analysis*). Cette méthode sera comparée à deux classifications basées sur des indices biophysiques dérivés des réflectances et liés à la teneur en eau de la canopée mais aussi à la surface foliaire. La dernière partie de la section sera consacrée à la prise en compte du voisinage spatial dans ces méthodes. La section 3.4 synthétisera et conclura sur les méthodes testées dans cette étude.

#### 3.1. Etat de l'art

Gao et al. (2020) passe en revue les études sur la détection de la dégradation des forêts par télédétection, regroupées par types de perturbations. Il s'agit notamment de l'exploitation forestière sélective, des incendies, de la culture itinérante, de l'extraction de bois de chauffage, des ravageurs (qui peuvent causer la défoliation des arbres), des ouragans, des tsunamis, de la chasse excessive (provoquant un amincissement du sous-étage) et de la sécheresse. Dupuis et al. (2020) recense les approches de télédétection utilisées pour étudier la dégradation des forêts tropicales humides, des drones (UAV) aux données satellitaires.

La structure de la forêt (c'est-à-dire les trouées de la canopée, la fragmentation forestière et l'évaluation de la biomasse) est le critère le plus largement mesuré par télédétection pour détecter l'état dégradé des forêts, tandis que la composition floristique (richesse spécifique, dominance d'espèces secondaires, présence d'espèces envahissantes) et la régénération sont plus difficiles à caractériser.

Les méthodes semi-automatiques de suivi de dégradation forestière reposent essentiellement sur trois types d'approches utilisant l'imagerie optique :

- Le type d'approche le plus rencontré est basé sur la valeur du pixel, souvent via des approches de démélange spectral. Ceci peut s'appliquer sur des images uniques, ou sur des séries temporelles ;
- Des approches basées sur la texture ;
- Des approches basées sur la présence de signes annexes.

L'imagerie radar et le LiDAR sont aussi parfois employés pour la détection des forêts dégradées en raison de leur sensibilité à la structure forestière, dont le changement peut être lié à la dégradation.

### 3.1.1. La détection des forêts dégradées par les méthodes de démélange spectral

Les approches de démélange spectral, qui distinguent des pixels dits purs, homogènes en termes d'occupation du sol, et faciles à classer contrairement aux pixels mélangés qui représentent des mélanges de matériaux distincts (végétation et sol dans le cas de forêts dégradées par exemple). Ces approches produisent le pourcentage de végétation active, de végétation morte et de sol nu à l'échelle du pixel (Morton et al., 2011). Le panorama des applications des méthodes de démélange spectral (SMA) est dressé dans cette section ; les principes sont exposés plus en détail dans la section 3.2.1.

En 2016, les données Landsat à partir desquelles ont été calculés les indices Normalized Difference Fraction Index (NDFI) par SMA ont permis une détection de dégradation dans des forêts semi-décidues et à feuillage persistant au Kenya par **Bewernick**. En 2014, une approche similaire proposée par **Shimabukuro** a pu identifier et cartographier les zones de dégradation des forêts causées soit par l'exploitation forestière sélective, soit par les incendies dans les écosystèmes tropicaux humides dans l'État du Mato Grosso au Brésil, à partir d'images Landsat Enhanced Thematic Mapper Plus (ETM+). **Hirschmugl** et al. (2014) s'appuient sur la même méthode au Cameroun et en République centrafricaine pour cartographier la dégradation des forêts sur une série temporelle Landsat, via une analyse de mélange spectral suivie d'une classification des courbes temporelles spectrales. La classification basée sur les pixels qui en résulte est ensuite agrégée aux zones de dégradation.

En 2003, la cartographie des forêts dégradées dans l'est amazonien est faite avec la même approche sub-pixellaire sur des images SPOT 4 à 20 mètres de résolution spatiale (**Souza Jr et al.**, 2003). L'étude montre une haute corrélation entre la biomasse aérienne des classes de forêts dégradées et la fraction de végétation non-photosynthétique (NPV). Ce résultat peut être expliqué par les critères utilisés par les auteurs pour définir la classe des forêts dégradées : dans ces travaux, ces forêts incluent les forêts récemment brûlées et/ou intensément brûlées et défrichées dans les 2 dernières années.

Le démélange spectral a permis notamment de détecter la dégradation forestière en Amazonie à partir de données de télédétection à résolution spatiale de 30 mètres (Bullock et al., 2020b ; Matricardi et al., 2020 ; Souza et al., 2013). Cependant, la résolution spatiale de 30 mètres est souvent considérée comme trop grossière pour cartographier de manière fiable l'exploitation forestière sélective à petite échelle (Lima et al., 2019). Il existe encore peu d'études de démélange spectral pour la cartographie d'occupation du sol à des résolutions spatiales plus fines, notamment à partir des données Sentinel-2 (de résolution spatiale de 10 mètres) (Phiri et al., 2020 ; Vermeulen et al., 2021 ; Kowalski et al., 2022). Les images à haute résolution spatiale (inférieure à 10 m) sont utilisées à une échelle plus locale et permettent une détection précise, mais impliquent des coûts plus élevés, ce qui les rend moins appropriées pour les analyses au niveau national (Gao et al., 2020).

D'autres études notables se basent sur l'analyse de séries temporelles SMA, qui est ici particulièrement pertinente en raison de la repousse rapide de la végétation dans les forêts tropicales humides. Par exemple, l'approche de détection de dégradation continue (CODED) effectue une analyse de mélange spectral à partir de laquelle sont calculées des séries temporelles de l'indice de fraction de différence normalisée (NDFI) à l'échelle régionale. Le changement dans le couvert arboré est détecté à l'aide d'une détection de « rupture » dans les séries temporelles ; la détermination du type de changement

(déforestation ou dégradation) est mise en œuvre avec des données d'entraînement et un classifieur d'apprentissage automatique. CODED a été appliqué avec succès en Amazonie, au Guatemala, au Népal et aux Fidji (Aryal et al., 2021 ; Bullock et al., 2020 ; Bullock et al., 2020a).

D'autres études se basent sur l'approche Breaks For Additive Seasonal and Trend (BFAST). Elles ont démontré que les séries temporelles peuvent être décomposées en composantes (tendancielles, saisonnières et résiduelles) et que les changements dans le couvert arboré peuvent être séparés du signal phénologique. L'approche BFAST, qui bénéficie du soutien de la FAO via sa plateforme Sepal, a été appliquée dans de nombreuses régions (Verbesselt et al., 2010 ; Verbesselt et al., 2012 ; DeVries et al., 2015 ; Dutrieux et al., 2015).

L'inconvénient majeur de l'analyse du démélange spectral est que les seuils sont déterminés empiriquement et sont, par conséquent, difficilement transférables à d'autres zones d'étude. La méthode SMA requiert l'identification et la sélection manuelle de pixels purs pour les valeurs d'étalonnage, ce qui a un impact direct sur les résultats et introduit un élément de subjectivité.

### 3.1.2. La détection des forêts dégradées par les signes annexes ou la texture

En imagerie optique, il existe d'autres approches de détection de forêts dégradées par l'utilisation de **signes indirects indicateurs** de dégradation. En 2004, de Wasseige et Defourny utilisent les sentiers forestiers comme indicateurs de présence de dégradation, car fréquemment empruntés par les lourds véhicules compactant et dégradant la terre, laissant apparent le sol nu de façon parfois permanente, grâce aux données Landsat et SPOT dans une forêt semi-décidue dégradée en République centrafricaine. Là encore, le besoin d'un contraste élevé, la repousse rapide de la végétation et la fréquence élevée de la couverture nuageuse, réduit la probabilité d'obtenir des images pertinentes pour une analyse temporelle de la dégradation forestière. Au Brésil, dans la forêt tropicale atlantique, les forêts perturbées sont détectées grâce à l'espèce d'arbre *Cecropia hololeuca*, un indicateur de perturbation des forêts, à partir d'images WorldView-3 (Wagner et al., 2020).

D'autres approches recourent à des indicateurs dérivés de la **texture** de la canopée. Ces indicateurs reposent sur des matrices de co-occurrence et utilisent la variance du signal dans une fenêtre spatiale donnée pour quantifier spatialement la distribution de la structure des cimes des arbres. C'est le cas des travaux de Bourgoïn et al. (2020) qui, à partir d'images à très haute résolution acquises par drones (10 cm de résolution spatiale) au Brésil, utilisent des paramètres de texture à partir de la méthode Fourier ou FOTO reposant sur des analyses fréquentielles (Couteron, 2002 ; Ploton et al., 2017), ainsi que des données altimétriques pour évaluer la structure du couvert forestier et pour construire une typologie liant l'historique de la dégradation et les états actuels. En effet, les paramètres de texture capturent le grain de la canopée et sont en corrélation avec la variabilité de la structure forestière. Les résultats montrent que la dégradation génère des textures de canopée spécifiques liées à l'historique de l'exploitation forestière et des incendies. L'étude démontre que les informations de texture permettent de caractériser efficacement les types de forêts dégradées et que les drones sont des outils prometteurs pour cette tâche en offrant des images à très haute résolution, et avec un meilleur contrôle des conditions d'acquisition que les satellites.



### 3.1.3. La détection des forêts dégradées par les indices de végétation

Il existe très peu d'études utilisant les indices de végétation pour détecter les forêts dégradées. Fréquemment mis en œuvre de manière opérationnelle en télédétection pour d'autres applications, les **indices de végétation** jouent sur les contrastes de réflectance spectrale caractéristiques de la végétation entre deux bandes spectrales, situées respectivement dans le visible (le plus souvent, la bande rouge) et le proche infrarouge. La production d'indices de végétation est une méthode largement utilisée pour fournir des paramètres biophysiques de la végétation. Les indices de végétation et les méthodes basées sur ces derniers ont l'avantage d'être simples sur le plan des calculs alors qu'elles sont généralement moins spécifiques aux sites et plus universellement applicables que les autres méthodes.

Les premiers indices de végétation ont comparé la réflectance dans le proche infrarouge (PIR) de la matière végétale à celle dans la partie rouge du spectre électromagnétique pour quantifier les paramètres de verdure de la végétation. La teneur en chlorophylle de la canopée a par exemple été estimée en utilisant le rapport PIR/rouge connu sous le nom de rapport simple (*simple ratio* ou SR) (Jordan, 1969). Le SR est ainsi la base de l'indice de végétation par différence normalisée (*Normalised Difference Vegetation Index* ou NDVI) (Rouse et al., 1974), qui est actuellement l'indice de végétation le plus utilisé comme mesure pour de nombreuses variables (Huang et al., 2021 ; Pettorelli et al., 2005 ; Delbart et al., 2006).

$$NDVI = \frac{PIR - rouge}{PIR + rouge}$$

Des versions modifiées du NDVI et du SR tel que l'indice de végétation ajusté au sol SAVI (Huete, 1988) ont été mis au point pour tenir compte de l'incertitude liée aux variations de condition du sol. Le SAVI incorpore un facteur de correction L dans la formule NDVI qui rend compte de la variation des propriétés spectrales du sol en faisant varier le facteur entre 1 pour la végétation basse et 0 pour la végétation dense. Sa formule est :

$$SAVI = \frac{PIR - rouge}{PIR + rouge + L} (1 + L)$$

$$avec L = 0.5$$

Le NDVI étant sujet à la saturation dans les zones à végétation dense telles que les forêts tropicales humides, l'indice EVI (pour Enhanced Vegetation Index) proposé par Huete et al. (2002) surmonterait cet obstacle. La formule de l'EVI est donnée par l'équation :

$$EVI = \frac{2.5 \times (PIR - rouge)}{(PIR + C_1 \times rouge - C_2 \times bleu + L)}$$

$$avec C_1 = 6, C_2 = 7 et L = 1$$

La plage de valeurs pour l'EVI est de -1 à 1, avec une végétation saine généralement autour de 0,20 à 0,80. Dans les zones de couvert forestier dense, les longueurs d'onde bleues peuvent être utilisées pour améliorer la précision du NDVI, car elles atténueraient les effets des aérosols selon Hasanah et al. (2020). Dans cette étude, l'EVI est mesuré sur des images Landsat 4 TM entre 1991 et 2014, sur Peleng, en Indonésie. Dans cette étude, les valeurs spectrales EVI sont classées par seuillage en 3 types : non-végétation (0-0.35), végétation clairsemée (0.36-0.5) et végétation dense (0.51-1). Les résultats cartographiques montrent que les forêts fortement dégradées se trouvent à une altitude plus basse où l'infrastructure routière (donc l'accessibilité) est bien développée, et les forêts les moins dégradées se trouvent à une altitude plus élevée, loin des habitations humaines.

La détection des forêts dégradées peut être réalisée avec des indicateurs de la teneur en eau du feuillage de la canopée, et notamment avec un indice qui impliquerait le moyen infra-rouge (Ceccato et al., 2001 ; Kunert et al., 2015 ; Zhao et al., 2021). La cause du stress hydrique dans le feuillage de la cime peut être due à une diminution de l'évapotranspiration dans les arbres, potentiellement liée à une modification structurelle de la forêt : la fragmentation peut provoquer des déficits d'évapotranspiration en bordure des fragments forestiers (Numata et al., 2021) et la coupe sélective des grands arbres permet à la lumière d'atteindre la végétation du sous-étage sciaphile. En conséquence, une concurrence plus intense sur le sol forestier avec des espèces pionnières héliophiles émergentes réduirait la disponibilité de l'eau et rend les forêts perturbées plus vulnérables au stress hydrique (Kunert et al., 2015).

En outre, dans les cartes de photo-interprétation obtenues et confirmé par la campagne de terrain, les forêts dégradées se trouvent généralement en lisière de massif ou de routes, c'est-à-dire adjacentes à des bords nouvellement exposés. La perte d'habitats naturels et en particulier la fragmentation, augmentent la présence de bords d'habitat qui sont des zones de transition sensibles aux effets de bord (Zhao et al., 2021). Une revue de littérature documentant 146 effets de bord montre que ceux-ci peuvent pénétrer à une distance de 100 m à l'intérieur des forêts (Broadbent et al., 2008). Les effets de bords peuvent se traduire par des changements dans le microclimat (Kunert et al., 2015, Laurance et al., 1998). Par exemple, les forêts de bords sont plus susceptibles de connaître des vents forts que les forêts intactes, et à une forte dessiccation forestière (Kapos, 1989 ; Williams-Linera, 1990 ; Giambelluca et al., 2003). Les forêts perturbées sont plus vulnérables au stress hydrique et en saison sèche, la dessiccation pénètre plus profondément dans la forêt qu'en saison humide (Kunert et al., 2015 ; Zhao et al., 2021). Les informations spectrales sont liées à la fois à l'eau et à la matière sèche contenues par unité de surface, mais aussi à la teneur en pigments foliaires. Le stress hydrique modifie le spectre de réflectance des feuilles, réduit leur surface et modifie leur architecture, influençant ainsi considérablement la réponse spectrale de la canopée (Cohen, 1991). Ici, le stress hydrique peut être détecté par télédétection en utilisant des plages de réflectance appropriées (voir revue des mesures de stress hydrique chez les plantes par télédétection par Govender et al., 2009). La télédétection est capable de suivre l'humidité dans la canopée dans les forêts fragmentées.

Pour estimer la teneur en humidité de la végétation, des méthodes appropriées utilisent diverses combinaisons de bandes spectrales infrarouge à ondes courtes (MIR) et proche infrarouge (PIR) selon la revue de Ceccato et al. de 2001, car elles sont très sensibles aux contraintes et végétation sénescence souffrant de stress hydrique.

Par exemple Briant et al. (2010) ont utilisé la réflectance infrarouge de l'imagerie MODIS (résolution spatiale ~ 463 m) pour évaluer la dessiccation des forêts de lisière de l'Amazonie brésilienne mettant en évidence un effet de lisière (bandes spectrales : 2 dans le proche infrarouge 841–876 nm et 6 dans le moyen infrarouge 1628–1652 nm). Les niveaux d'humidité dans la canopée ont été estimés en saison sèche sur une période de huit ans, sur une superficie de 100 000 km<sup>2</sup> par télédétection, par l'utilisation du Short-wave Infrared Water Stress Index (SIWSI) (Cheng et al., 2006). Le SIWSI, proposé par Fensholt et Sandholt en 2003, est décrit selon la formule :

$$SIWSI = \frac{MIR - PIR}{MIR + PIR}$$

Les auteurs concluent que les forêts intactes ne présentent aucun changement détectable dans leur teneur en eau de la canopée, alors que les forêts adjacentes aux déboisements présentent un stress hydrique important dans leur canopée. Les effets de la déforestation sur la dessiccation du couvert sont moins prononcés dans les paysages moyennement fragmentés (avec un couvert forestier restant de 65% et 51%), où la dessiccation du couvert s'étendait sur 1 à 1,5 km à l'intérieur des forêts, alors que dans les paysages très fragmentés (20% de couvert forestier), la dessiccation pénétrait jusqu'à 2,7 km dans les forêts.

Le MSI a été proposé par Hunt & Rock en 1989 pour détecter les changements dans la teneur en eau des feuilles en utilisant le rapport de réflectance entre MIR et PIR.

$$MSI = \frac{MIR}{PIR}$$

#### **3.1.4. La détection des forêts dégradées par les autres méthodes (radar, LiDAR)**

En imagerie radar, les capteurs RSO (radar à synthèse d'ouverture) complètent les capteurs optiques car ils permettent des observations sur des sites nuageux. La détection des forêts dégradées est le plus souvent réalisée à travers la stéréo-radargrammétrie grâce à sa sensibilité à la texture du couvert forestier impacté (Kuck et al., 2021 ; Deutscher et al., 2013). Cependant, le signal RSO sature dans les forêts à biomasse moyenne à élevée (entre 30 et 100 tonnes C ha<sup>-1</sup>) et n'est donc pas adapté pour cartographier la biomasse forestière dans toutes les conditions (Lucas et al., 2010 ; Ryan et al., 2012 ; Ryan et al., 2014 ; Mitchard et al., 2009). L'usage des approches multi-sources reste marginal (Reiche et al., 2013 ; Montesano et al., 2013 ; Bourgoïn et al., 2018).

Le LiDAR, d'autre part, offre la possibilité d'évaluer les changements de biomasse forestière en estimant la distribution tridimensionnelle de la canopée, ainsi que la topographie sous les canopées. Le LiDAR fournit des estimations précises de la hauteur de la végétation et de la structure de la canopée.

Les données LiDAR aéroportées ajoutent de la valeur à la quantification de la dégradation mais ne sont pas disponibles sur de grands territoires et une fréquence temporelle élevée. Contrairement aux données satellitaires optiques et radar qui sont plus abordables et régulièrement disponibles, le LiDAR est un outil coûteux pour les acteurs locaux. Il est important de mentionner la mission GEDI (Global Ecosystem

Dimension Investigation) d'acquisitions LiDAR menée par l'Université du Maryland en collaboration avec la NASA (<https://gedi.umd.edu/mission/mission-overview/>). Cette mission de 2 ans, lancée en décembre 2018, effectue des mesures de la hauteur de la canopée, de la structure verticale de la canopée et de l'élévation de la surface et s'avère prometteuse pour améliorer les mesures de la biomasse forestière. Tous les produits de données GEDI sont disponibles en téléchargement gratuit (<https://gedi.umd.edu/data/download/>).

## **3.2. Evaluation des méthodes SMA pour la détection des forêts dégradées dans le contexte guinéen**

Parmi les méthodes de détection des forêts dégradées par imagerie optique présentées dans l'état de l'art, une approche est retenue. Couramment rencontrée dans la littérature pour cartographier les forêts dégradées, l'analyse par mélange spectral de plusieurs membres (ou SMA pour *spectral mixture analysis*) est explorée dans la section 3.2.1 pour estimer la fraction de végétation photosynthétiquement active. Dans les sections 3.2.2. et 3.2.3., des indices de végétation et biophysiques générés à partir des images Sentinel-2 seront analysés entre 2015 et 2020 pour améliorer la discrimination des forêts dégradées. Enfin, dans la section 3.2.4., l'apport du voisinage spatial sera testé et comparé aux méthodes standard basées sur le pixel.

Dans chaque méthode étudiée, les 23 acquisitions Sentinel-2 sont utilisées pour produire les analyses temporelles d'indices.

### **3.2.1 Méthodes de détection des forêts dégradées par SMA**

Les méthodes par SMA sont les plus utilisées dans les études antérieures sur la télédétection de la dégradation (Souza et al., 2003 ; Souza et al., 2013 ; Morton et al., 2011 ; Shimabukuro, 2014 ; Hirschmugl et al., 2014 ; Bewernick, 2016 ; Bullock et al., 2020b ; Matricardi et al., 2020) (voir section 3.1.1).

Le démixage spectral est le processus de décomposition de la signature spectrale d'un pixel "mêlé" en un ensemble de membres de référence (ou *endmembers*) et de leurs abondances correspondantes. Cette technique de démélange spectral détermine la fraction en couvert de différents constituants dans un pixel. En d'autres termes, l'analyse SMA cherche à déterminer la composition probable de chaque pixel de l'image. Les pixels contenant plusieurs types de couvertures sont appelés pixels mélangés. Les pixels « purs » ne contiennent qu'une seule caractéristique ou classe. Par exemple, un pixel mélangé peut contenir de la végétation, un sol nu et une croûte de sol (fig. 30). Un pixel pur ne contiendrait qu'une caractéristique, telle que la végétation. Les pixels mélangés peuvent poser des problèmes dans les classifications d'image classiques (classification supervisée ou non supervisée, par exemple), car le pixel appartient à plusieurs classes mais ne peut être affecté qu'à une seule classe. Une façon de résoudre le problème des pixels mélangés consiste à utiliser l'analyse subpixelaire avec une imagerie multispectrale.




Figure 30 : schéma représentant deux pixels purs et un pixel mélangé dans une carte d'OCS.

L'analyse subpixelaire du mélange spectral est largement utilisée en télédétection pour estimer les fractions d'abondance des matériaux présents dans un pixel d'image (Asner & Lobell, 2000 ; Clasen et al., 2015 ; Mylona et al., 2012 ; Reiche et al., 2013 ; Roberts et al., 1998 ; Somers & Asner 2013 ; Souza et al., 2003 ; Souza et al., 2005). Pour qu'un estimateur basé sur une analyse SMA produise des quantités précises d'abondance matérielle, il nécessite généralement deux contraintes imposées au modèle de mélange linéaire.

La première contrainte exige que la somme des fractions d'abondance des matériaux présents dans un pixel de l'image soit égale à un, et la seconde impose une contrainte selon laquelle ces fractions d'abondance doivent être non négatives. Alors que la première contrainte est facile à traiter, la seconde contrainte est difficile à mettre en œuvre car elle résulte en un ensemble d'inégalités et ne peut être résolue que par des méthodes numériques. En conséquence, la plupart des méthodes basées sur la SMA ne sont pas contraintes et produisent des solutions qui ne reflètent pas nécessairement les fractions d'abondance réelle des matériaux. Dans ce cas, ils ne peuvent être utilisés qu'aux fins de la détection, de la discrimination et de la classification des matériaux, mais pas à des fins de quantification.

L'analyse SMA modélise les signatures spectrales des pixels sous la forme d'une combinaison linéaire de signatures spectrales de deux ou plusieurs composants du sol. Les membres de référence (ou *endmembers*) sont mesurés sur des pixels sélectionnés de canopées, de matériaux non photosynthétiques (par exemple, de tiges) et de sols dans l'image et forment une bibliothèque de signatures spectrales. Ces bibliothèques de référence permettent de développer plusieurs modèles linéaires candidats. Chaque modèle candidat est appliqué à l'image puis, pixel par pixel, évalué en termes de fractions, d'erreur quadratique moyenne (RMSE) et de résidus. Si un modèle répond à tous les critères, il est répertorié comme candidat pour ce pixel.

L'équation fondamentale de l'analyse SMA est :

$$L_{i\lambda} = \sum_{k=1}^N f_{ki} \times L_{k\lambda} + \varepsilon_{i\lambda} \text{ et } \sum_{k=1}^N f_{ki} = 1$$

où un pixel mélangé à la réflectance spectrale  $L_{i\lambda}$  à l'emplacement  $i$  est modélisé comme la somme de  $N$  membres de référence,  $L_{k\lambda}$ , couvrant chacun une fraction  $f_{ki}$  du pixel. Le terme résiduel  $\varepsilon_{i\lambda}$  décrit la partie non modélisée de la réflectance, et le modèle choisi pour chaque pixel est celui qui minimise l'erreur quadratique moyenne (RMSE) sur le nombre  $B$  de bandes utilisées dans le démélange :

$$RMSE = \left[ \sum_{k=1}^B \frac{(\varepsilon_{i\lambda})^2}{B} \right]^{\frac{1}{2}}$$

Dans le cas de Sentinel-2, les membres de références et leurs signatures spectrales sont mesurés sur les 13 bandes individuellement. Les signaux de pixels mixtes sont généralement modélisés à l'aide d'un modèle de mélange linéaire (LMM). Un modèle de « démélange » convertit les comptes numériques de l'image en fractions numériques de membres finaux (« endmembers »). Les endmembers sont des spectres qui sont des proxys des matériaux au sol. Ici, nous supposons que dans chaque pixel, 4 membres sont présents en diverses fractions :

- La végétation photosynthétique (VP)
- La végétation non-photosynthétique (VNP)
- Le sol
- L'eau

Les fractions  $x_{VP}$ ,  $x_{VNP}$ ,  $x_{Sol}$ ,  $x_{Eau}$  sont les solutions de l'équation matricielle suivante :

$$\begin{pmatrix} B1_{VP} & B1_{VNP} & B1_{sol} & B1_{eau} \\ B2_{VP} & B2_{VNP} & B2_{sol} & B2_{eau} \\ B3_{VP} & B3_{VNP} & B3_{sol} & B3_{eau} \\ B4_{VP} & B4_{VNP} & B4_{sol} & B4_{eau} \\ B5_{VP} & B5_{VNP} & B5_{sol} & B5_{eau} \\ B6_{VP} & B6_{VNP} & B6_{sol} & B6_{eau} \\ B7_{VP} & B7_{VNP} & B7_{sol} & B7_{eau} \\ B8_{VP} & B8_{VNP} & B8_{sol} & B8_{eau} \\ B8A_{VP} & B8A_{VNP} & B8A_{sol} & B8A_{eau} \\ B9_{VP} & B9_{VNP} & B9_{sol} & B9_{eau} \\ B10_{VP} & B10_{VNP} & B10_{sol} & B10_{eau} \\ B11_{VP} & B11_{VNP} & B11_{sol} & B11_{eau} \\ B12_{VP} & B12_{VNP} & B12_{sol} & B12_{eau} \end{pmatrix} \begin{pmatrix} x_{VP} \\ x_{VNP} \\ x_{sol} \\ x_{eau} \end{pmatrix} = \begin{pmatrix} B1 \\ B2 \\ B3 \\ B4 \\ B5 \\ B6 \\ B7 \\ B8 \\ B8A \\ B9 \\ B10 \\ B11 \\ B12 \end{pmatrix}$$

Il est impératif que le choix des membres finaux soit fait sur des zones les plus homogènes possibles. La nature mixte des informations spectrales limite considérablement la précision de l'analyse spectrale. Car aucun pixel, aussi petit soit-il, ne représente des caractéristiques homogènes complètes, et le signal mesuré par le capteur est le résultat des interactions du rayonnement électromagnétique avec de multiples constituants à l'intérieur de chaque pixel.

Le succès d'une analyse SMA repose également sur le type de « endmembers » et de leurs signatures spectrales correspondantes. En effet, des membres finaux qui sont spectralement similaires conduisent

à des images de fractions de membres finaux qui sont physiquement inexactes comparées à la réalité sur le terrain. La similarité entre les membres finaux entraîne une forte corrélation entre les signatures spectrales de ces dernières, ce qui impacte la précision des démixtes des pixels mixtes. Différentes solutions pour sélectionner le type de membres finaux pour une scène spécifique ont été proposées, la plus répandue étant le test manuel de différents ensembles de membres finaux (Somers et al., 2011). L'abondance de chacun de ces membres varie dans le temps, reflétant les processus opérant sur le sol (régénération, changements saisonniers). Pour la détection des forêts dégradées, nous supposons que ces dernières peuvent être décrites comme un mélange de végétation et de sol ; la fraction de sol y est plus élevée qu'en forêt dense, et à l'inverse, la fraction de végétation photosynthétique plus faible.

Le choix des endmembers pour la cartographie des forêts dégradées s'est porté sur ceux utilisés dans d'autres études de démixte spectral. La sélection s'est faite manuellement, en s'appuyant sur les signatures spectrales. Le plus simple est le membre « eau », dont des pixels purs ont été choisis sur un lac (fig. 31). Le membre « sol » a été sélectionné sur des pixels de sols nus. Le membre « végétation photosynthétique » a été établi sur de la forêt dense, en plein massif forestier pour maximiser la pureté des pixels. Enfin, le membre « végétation non-photosynthétique » est proposé ici sur de la végétation rase, dont la signature spectrale semble proche du sol, mais montre un pic dans les gammes du moyen infrarouge (B11) contrairement au sol. La végétation non photosynthétique inclut également les tiges, la litière, les matières sénescents et le bois mort ; elle est courante dans notre zone d'étude en raison du climat de la région, de la couverture végétale relativement éparse et des sécheresses saisonnières. Ainsi, l'acquisition simultanée de la couverture fractionnelle de la VP et de la VNP dans le massif de Ziama peut potentiellement fournir de nouvelles informations pour le suivi des forêts dégradées.





Figure 31 : Signatures spectrales de pixels « purs » sur de la végétation photosynthétiques, de la végétation non-photosynthétique, du sol et de l'eau. L'exemple est pris sur l'image du 15/02/2019. Dans une image en abondances, chaque pixel « mélangé » est une combinaison linéaire de ces 4 membres purs.



### 3.2.2. Résultats de l'analyse SMA

L'analyse SMA a été réalisée sur les 3 saisons sèches de 2016 à 2019 (tableau 4) sur le massif de Ziama, totalisant 22 images Sentinel-2. Les pixels analysés ont été sélectionnés sur les forêts denses et les forêts dégradées de la carte ZAEG. Une tendance se détache des analyses multitemporelles SMA sur les 2 types de forêts dense et dégradée. Les forêts denses présentent une fraction de végétation photosynthétique (VP) plus élevée et une abondance en végétation non-photosynthétique (VNP) et en sol moins forte que les que les forêts dégradées (test de Student apparié,  $p < 0.005$ ) (fig. 32). Ces observations montrent les mêmes tendances vues dans les études de Souza et al., (2013), Hirschmugl et al. (2014) et Bewernick (2016).

Ceci peut être expliqué par la grande densité des houppiers caractéristiques des forêts denses donc un contenu chlorophyllien plus élevé. Par leur canopée plus clairsemée, les forêts dégradées montrent des fractions en contenu chlorophyllien plus faible mais aussi des fractions en contenu non-photosynthétique et en sol plus fortes, potentiellement dû au sous-bois, aux matières sènescentes et à la litière.

Les fractions SMA montrent des différences chez les forêts dégradées et chez les forêts denses sur les 3 saisons sèches entre 2016 et 2019.




Figure 32 : Analyse multi-temporelle des valeurs d'abondance des 4 membres finaux de l'analyse subpixelaire SMA sur les forêts dense (rouge) et dégradée (vert) entre 2016 et 2019. Les pixels analysés ont été sélectionnés sur les forêts denses et les forêts dégradées de la carte ZAEG.

### 3.2.3. Classification sur les résultats de l'analyse SMA

#### 3.2.3.1. Classification Random forest

Les combinaisons de fractions permettent de définir des images en abondances sur lesquelles une classification supervisée Random Forest est appliquée. Les classificateurs **Random Forest** (RF) (Breiman et al., 2001) sont largement utilisés en télédétection pour leurs performances ainsi que leur capacité à traiter de grands ensembles de données et leur vitesse d'exécution (Pelletier et al., 2016). Dans la classification RF, l'ensemble de données initial est rééchantillonné de manière aléatoire pour générer plusieurs sous-ensembles de données. Un grand nombre  $K$  d'arbres de décision (Breiman et al., 2001) sont construits à partir de chacun des sous-ensembles de données. Pour chaque nœud d'arbre,  $m$  attributs sont tirés au hasard. Parmi ces  $m$  attributs, celui qui sépare le mieux le sous-échantillon est sélectionné et devient le critère du nœud. Cette opération est effectuée sur tous les nœuds de chacun des  $K$  arbres. Pour chaque pixel, la classe attribuée au pixel sera la majorité votée par tous les  $K$  arbres de décision (figure 33).




Figure 33 : schéma simplifié de l'algorithme Random Forest.

### 3.2.3.2. Evaluation des résultats cartographiques

La carte de référence photo-interprétée (construite au chapitre 2) indique la classe réelle du pixel d'intérêt et permet la validation du modèle RF. Une matrice de confusion est produite sur la base d'une prédiction correcte du nombre total de pixels, à partir de laquelle est produit la précision globale (OA) pour la comparabilité des méthodes.

La matrice de confusion et les indices dérivés tels que la précision globale (Overall Accuracy ou OA) et les précisions utilisateur et producteur sont utilisés comme mesures de performance de l'efficacité des modèles. La précision globale (OA) nous indique essentiellement quelle proportion de pixels est correctement classée sur la totalité des pixels. La précision globale est généralement exprimée en pourcentage, une précision de 100 % étant une classification parfaite où tous les pixels sont classés correctement.

À partir de la matrice de confusion, la précision producteur et la précision utilisateur peuvent être calculées. La précision producteur est le nombre de pixels correctement classés divisé par le nombre total de pixels pour cette classe dans les données de référence. La précision utilisateur est calculée en prenant le nombre total de classifications correctes pour une classe particulière et en le divisant par le nombre total de pixels de la classe dans la carte classée. Les modèles doivent être capables de classer cette image avec une précision globale minimale de 85%, en respectant les standards requis par la méthodologie VCS (Verified Carbon Standard).

### 3.2.3.3. Résultats

Pour tester le potentiel de discrimination de l'analyse temporelle SMA, un premier test de classification d'image a été réalisé sur les 10 images d'abondances SMA de 2016 à 2017 (18/10/2016, 7/11/2016, 7/12/2016, 17/12/2016, 27/12/2016, 16/01/2017, 26/01/2017, 5/2/2017, 7/12/2017 et 17/12/2017) ; un second test est effectué sur toute la série temporelle 2016-2019 de 22 images.

Pour une classification d'image optimale, la réalisation des régions d'intérêt (Regions Of Interest ou ROI) est décisive. Les ROI doivent sélectionner les pixels les plus caractéristiques des forêts denses, des forêts dégradées et des zones non-forêt, et être distribués sur l'étendue de la zone d'étude. Le choix des échantillons pour la classe forêt dense s'est porté sur les parties les plus homogènes du massif. Les polygones d'entraînement pour la classe des forêts dégradées ont été choisis sur deux transects forestiers. Les échantillons de la classe non-forêt ont été répartis sur zone d'étude sur les cultures annuelles, les cultures de bas-fond, les plantations, les sols nus, les zones urbaines, les cours d'eau et les savanes.

Le résultat de classification sur la courte série temporelle 2016/2017 est illustré en figure 34, en B. Le résultat cartographique est comparé aux forêts dégradées cartographiées par photo-interprétation sur la carte de référence 2017 illustrées en C et confirmées par le forestier lors de la campagne de terrain en avril 2019 (transects illustrés en rouge). Malgré le pouvoir discriminant des fractions SMA sur 2016/2017 vu en 3.2.1.1, la courte série temporelle ne suffit pas à détecter les forêts dégradées par classification d'image.

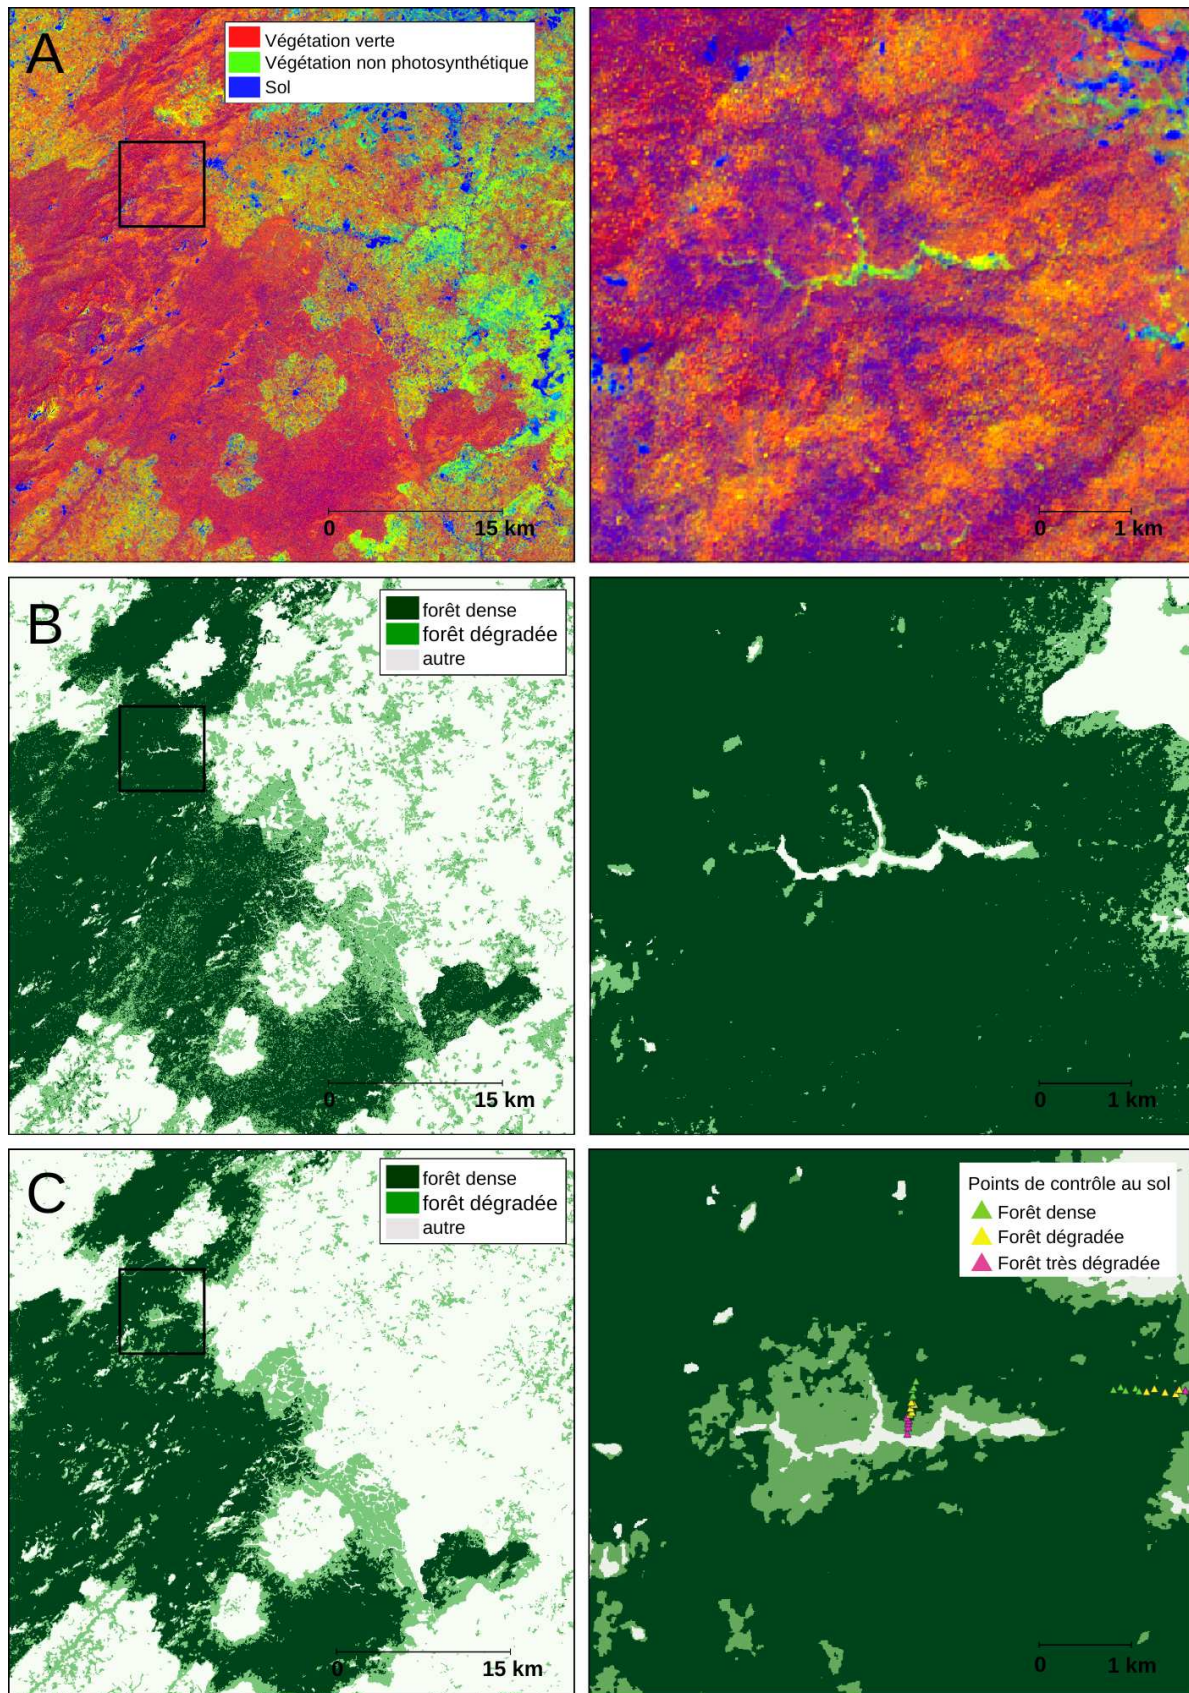


Figure 34 : A) composition colorée des fractions SMA extraites des radiométries de S2 de 2015 (fraction de Végétation verte, fraction de Végétation non photosynthétique et fraction de Sol dans les canaux RVB respectivement) ; B) résultat de classification multidates à partir de 10 images d'abondances SMA entre 2015 et 2017 ; C) carte de référence photo-interprétée de 2017, à laquelle sont superposés les transects de la campagne de terrain de 2019.

Les 4 fractions VP, VNP, sol et eau sont ensuite empilées sur les 22 dates de 2015 à 2019. En intégrant toute la série temporelle dans la classification, les données multi temporelles SMA permettent de mieux séparer les classes de forêts dense et dégradée en regroupant les pixels ayant une histoire similaire. Ceci est probablement dû au fait que l'emploi de séries temporelles plus longues entraîne l'implication de plus de couches contenant des informations pertinentes.

La classification SMA sur 22 dates est testée selon 2 modalités : 2 séries distinctes de membres finaux de références sont sélectionnées (fig.35), c'est-à-dire que des polygones différents sont choisis sur des zones homogènes de massifs (VP), de végétation rase pour la végétation non-photosynthétique (VNP), de sol et d'eau. A partir de ces 2 séries de membres finaux de référence, le même algorithme de démixage spectral a été appliqué sur les 22 images Sentinel-2.




Figure 35 : localisation des deux séries de membres finaux de référence.

Les résultats de classification SMA sur les 2 séries temporelles sont donnés en figure 36. Pour la 1<sup>ère</sup> classification, la précision globale est de 0.819 ; les précisions producteur des classes 'forêt dense', 'forêt

dégradée' et 'autre' sont respectivement de 0.876, 0.533 et 0.878 ; et enfin, les précisions utilisateur des classes 'forêt dense', 'forêt dégradée' et 'autre' sont respectivement de 0.785, 0.531 et 0.947.

La 2<sup>ème</sup> classification multi-temporelle est exécutée sur les 22 dates avec les mêmes polygones d'entraînement. Malgré une précision globale supérieure à 85%, on observe par exemple que les forêts dégradées au sud-ouest de la zone d'étude sont classées en forêt dense, que les plantations d'hévéas sont considérées comme forêts dégradées et qu'un cours d'eau est classé en forêt dense (zooms respectivement de gauche à droite dans la figure 36, panneau de droite). Il apparaît clairement que la sensibilité aux membres fins de référence est un problème important pour la transférabilité de la méthode SMA.

En conclusion, bien que les résultats de classification multi-date produits à partir de l'estimation des fractions de VP, VNP et de sol aient montré une bonne concordance avec les données de terrain, il existe des problèmes potentiels liés à la généralisation des membres fins dans la méthode SMA. En effet, cette approche dépend fortement des valeurs de référence utilisées dans les équations de démixage spectral. La sélection des membres fins, qui sont généralement choisis à partir des données d'image, est essentielle pour l'estimation précise de la couverture fractionnée. Ceci rend la méthode région-spécifique et fortement dépendante de l'expertise de l'opérateur.

Cette approche exige aussi une cohérence et une constance dans le choix des membres fins de référence, notamment pour des classes complexes comme celle des forêts dégradées qui montre une grande amplitude de radiométries. Cette difficulté est amplifiée dans notre étude car la détermination des membres fins sur l'image nécessite l'existence de pixels purs, or ces derniers sont rarement disponibles à une échelle spatiale de 10 m, en particulier dans les régions soumises à des climats saisonniers et sur de la végétation à caractère décidu comme en Guinée. La sélection de pixels purs, homogènes et constants dans l'espace y est particulièrement délicate.

Il est donc, *a priori*, possible de détecter les forêts dégradées à large échelle en utilisant l'analyse SMA dérivée des séries temporelles Sentinel-2 mais la méthode n'est pas retenue pour son application et sa transférabilité dans le projet ZAEG. Le choix des membres fins de référence est sujet à une part de subjectivité du télédéacteur, c'est un biais qui peut être amplifié dans une équipe de plusieurs opérateurs. Par ailleurs, les résultats montrent une instabilité des résultats lorsque le nombre d'images d'entrée décroît, la cartographie correcte ayant exigé l'utilisation de 22 images réparties sur 4 années.

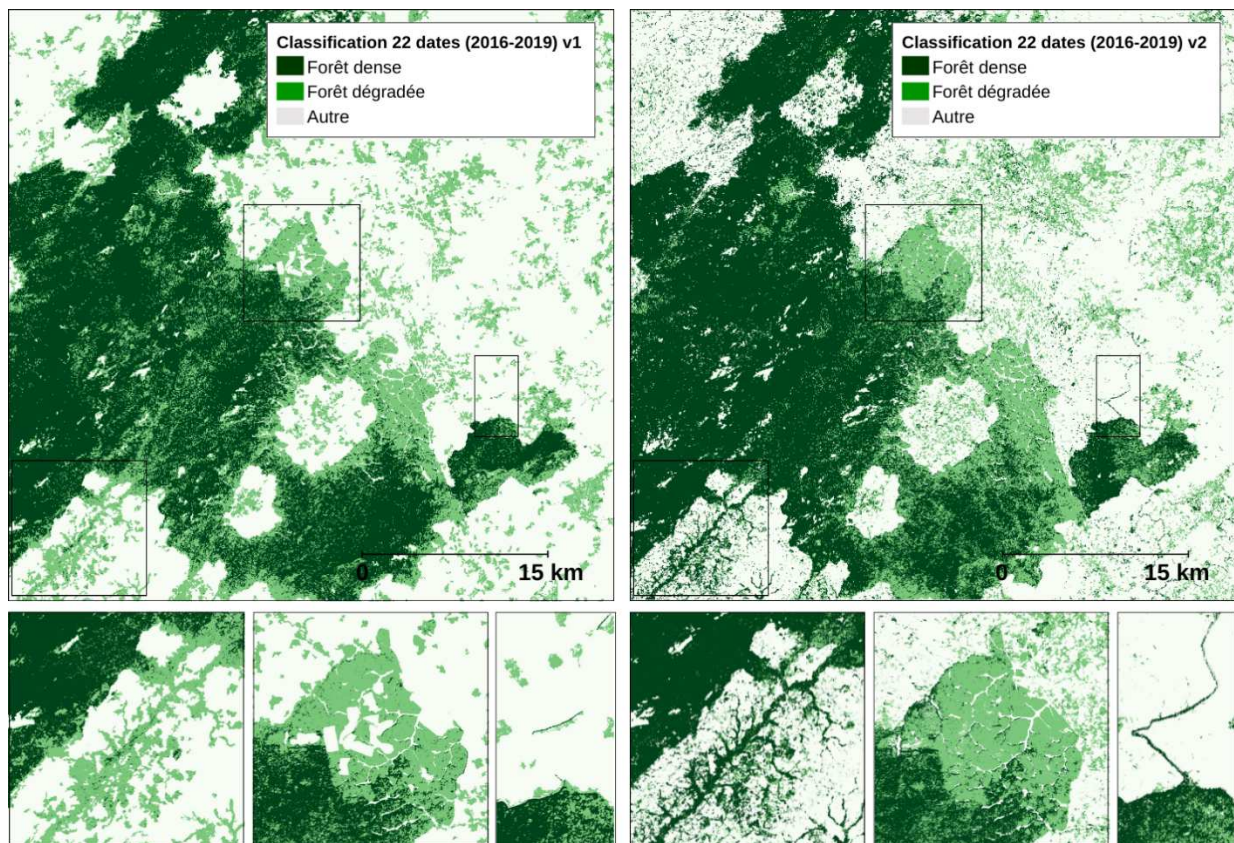


Figure 36 : résultat brut de classification multitemporelle SMA (22 dates), à partir de 2 séries différentes de membres finaux de référence. 3 agrandissements sont illustrés par des rectangles sur la carte.

### 3.3. Analyse des variations temporelles des indices spectraux

Une première analyse des réflectances Sentinel-2 de 2015 à 2021 (Fig. 26) montre la difficulté de discerner les forêts dégradées des forêts denses sur la seule base des bandes rouge (B04), vert (B03) et PIR (B08), les bandes utilisées pour photo-interpréter les images SPOT-6 dans le projet ZAEG. En revanche, on note que la série temporelle du MIR (B11) sur les forêts très dégradées lèvent considérablement la confusion entre les 2 classes. Sa seule utilisation ne suffit pas pour détecter les degrés de dégradation plus légers, mais le comportement radiométrique du MIR observé dans le graphique suggère des propriétés spectrales des éléments du couvert spécifiques ; notamment la plus faible teneur en eau dans les feuilles des forêts très dégradées.

Dans un contexte de détection de dégradation des forêts, une série de ces indices de végétation a été testée, en partant du postulat que le NDVI (indice de végétation par différence normalisée) et ses variantes sont utiles pour la différenciation de la végétation stressée et sénescente, à celle demeurée intacte (fig. 37).





la teneur en eau la plus élevée dans son feuillage de toutes les observations et les niveaux les plus bas de stress hydrique dans le feuillage de la canopée (valeurs MSI les plus basses).

Les résultats suggèrent une teneur réduite en humidité des feuilles dans les forêts de lisière et le couvert agroforestier par rapport au couvert forestier non perturbé. L'hypothèse de stress hydrique est corroborée par l'application de l'indice de stress hydrique (MSI), impliquant les bandes PIR et MIR, significativement plus élevé dans les forêts dégradées que dans les forêts denses (test de Student,  $p < 0,005$  en saison sèche).

Parmi les indices existants liés au stress hydrique, nous avons utilisé l'indice de stress hydrique (MSI) et la teneur en eau de la canopée (CWC), un indice biophysique présenté dans la section suivante 4.3.3., qui diffère fortement dans sa conception. Les résultats plus subtils obtenus sur le NDVI indiquent qu'il serait intéressant de conserver l'information sur le matériel chlorophyllien qui peut être résumé à travers l'index LAI. Dans ce qui suit, la variabilité de ces indices est explorée pour évaluer leur capacité à améliorer la détection de la dégradation. Cependant, l'évaluation de la relation entre ces indices et le niveau de stress hydrique sort du cadre de la thèse.

### **3.4. Utilisation des indices biophysiques pour la détection des forêts dégradées**

Au-delà des indices spectraux, des variables biophysiques peuvent être dérivées des données de télédétection à l'aide d'algorithmes calibrés par la modélisation du transfert radiatif (Kobayashi et al., 2010). Les deux variables biophysiques que sont l'indice de surface foliaire (LAI) et le contenu en eau de la canopée (CWC) sont extraites des images Sentinel-2 à l'aide de l'outil de traitement biophysique de Sentinel-2 ToolBox (Weiss & Baret, 2016). L'outil présente une base de données des caractéristiques de la végétation et des réflectances Sentinel-2 associées provenant d'une scène de référence. Les modèles de simulation estiment ensuite les caractéristiques de la canopée à partir des réflectances du haut de la canopée de l'image analysée.

L'indice de surface foliaire (LAI) est défini comme la moitié de la surface totale du feuillage de la canopée par unité de surface au sol (Chen et Black, 1992). Il est devenu l'un des paramètres les plus importants pour caractériser le feuillage de la végétation, depuis sa première définition en 1947 (Bréda, 2003 ; Chen et al., 1997 ; Watson, 1947), et est répertorié comme une variable climatique essentielle (ECV) du Système mondial d'observation du climat (SMOC). La valeur dérivée du satellite est le LAI total de toutes les couches de la canopée, y compris le sous-étage, ce qui peut représenter une contribution très importante, notamment pour les forêts.

Le LAI peut être considéré comme le principal indicateur de la productivité des plantes et il est lié aux caractéristiques structurelles d'un écosystème forestier. Le suivi de la répartition et des changements de LAI permet d'évaluer la croissance et la vigueur de la végétation.

En parallèle, le paramètre de contenu en eau de la canopée (CWC) reflète le contenu en eau des feuilles. Il est défini comme la quantité d'eau liquide présente dans le feuillage de la canopée exprimée en L/m<sup>2</sup> et constitue un indicateur de l'état du feuillage de la canopée. Le CWC varie en fonction de l'état hydrique

de la végétation et est généralement calculé comme le produit de la teneur en eau des feuilles et de l'indice de surface foliaire LAI (Clevers et al., 2010). Le CWC est généralement utilisé pour surveiller la sécheresse de la végétation (Trombetti et al., 2008).

Les détails complets pour extraire conjointement le LAI et le CWC à partir des images Sentinel-2 sont donnés dans un document décrivant les algorithmes pour les produits de niveau 2 mis en œuvre dans la Sentinel ToolBox<sup>13</sup> (Weiss & Baret, 2016). Le CWC, le LAI et le MSI ont été calculés sur les 23 images S2 pour une analyse temporelle sur les forêts denses et dégradées.

Les variations temporelles du LAI, du MSI et du CWC sont examinées sur les mêmes échantillons de types de couverts arborés (forêt dégradée de ZAEG, forêt dense, agroforêts, plantations, transects de terrain) qu'au chapitre 2. Les 23 acquisitions Sentinel-2 sont utilisées pour produire une analyse temporelle des indices MSI, CWC et LAI sur ces différents échantillons afin d'examiner les différences d'indices entre les systèmes agroforestiers, les plantations d'arbres, les forêts denses et dégradées.

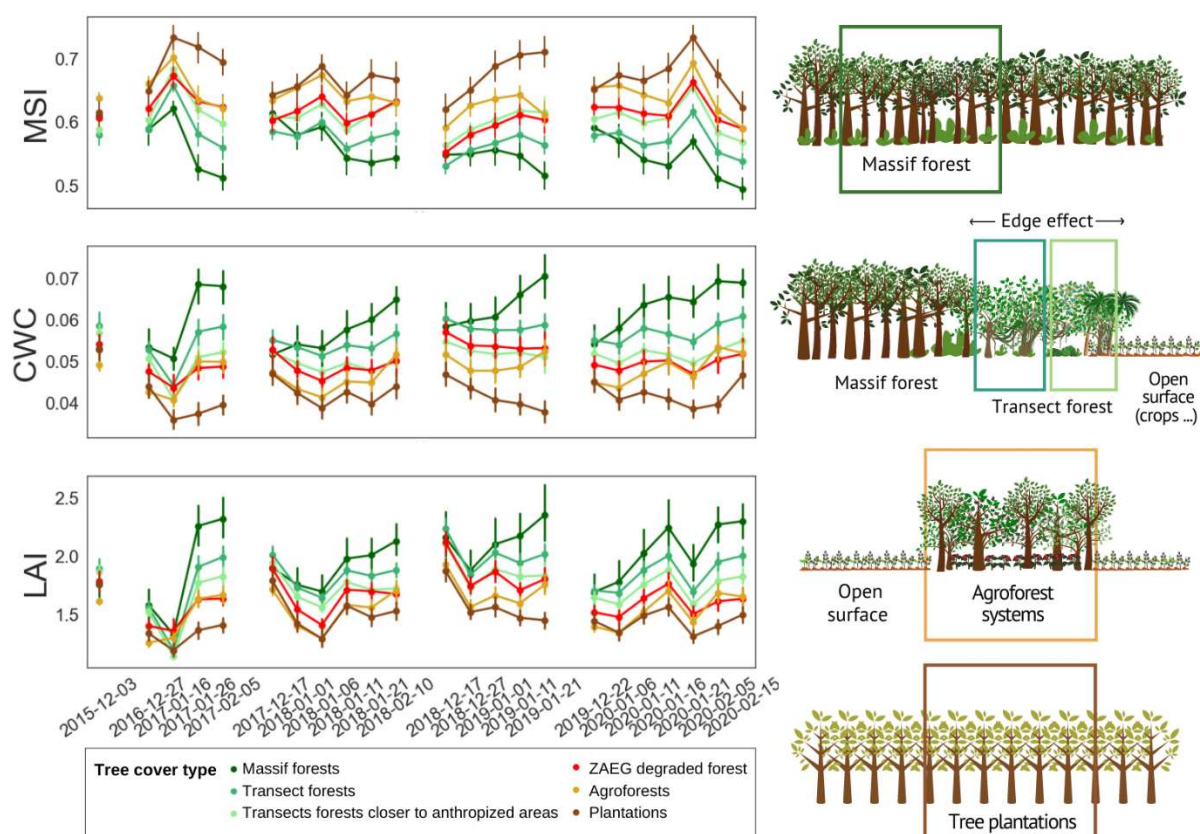


Figure 38 : des séries temporelles d'indices de télédétection sur les échantillons de type de forêt, choisis sur la carte ZAEG (plantations d'arbres en marron, agroforêts en orange, forêts de massif en vert foncé), et à partir d'observations au sol dans des forêts en transect divisées en 2 parties (une partie plus proche du massif forestier, l'autre en bordure). L'emplacement des pixels est indiqué sur la figure 4. Les indices de télédétection sont : l'indice de stress hydrique

<sup>13</sup> [https://step.esa.int/docs/extra/ATBD\\_S2ToolBox\\_L2B\\_V1.1.pdf](https://step.esa.int/docs/extra/ATBD_S2ToolBox_L2B_V1.1.pdf)

(MSI), le contenu en eau de la canopée (CWC) et l'indice de surface foliaire (LAI), calculés pour chaque image Sentinel 2 (tableau 4).

Les mesures répétées de Sentinel-2 sur les signaux CWC, LAI et MSI ont montré des différences significatives entre la forêt de massif (en vert sur les graphiques) d'une part, et les plantations d'arbres, les forêts de transect de terrain et les agroforêts d'autre part. Les forêts de massif présentent les valeurs de LAI les plus élevées par rapport aux autres types de forêts (fig. 38). De plus, les indices de teneur en eau diffèrent également fortement, avec le MSI le plus élevé et le CWC le plus faible pour la forêt de massif que pour les autres couverts arborés.

Les forêts de transect ont été divisées en 2 parties : une partie plus proche du massif forestier, l'autre à la lisière de la forêt. Cette dernière présente un MSI plus élevé et un CWC plus faible, ce qui peut être justifié par son exposition aux zones anthropisées voisines. Les différences entre chaque profil ne sont pas constantes dans le temps.

En résumé, il existe presque toujours une distinction nette entre les forêts de massif et les forêts de plantation, et des différences plus subtiles entre les deux : la forêt de lisière légèrement dégradée, proche de la forêt de massif, en jaune dans le graphique, affiche des valeurs d'indice intermédiaires entre la forêt de massif et les trois autres types de forêts dégradées qui diffèrent à peine (agroforêts, forêts dégradées détectées par ZAEG, forêts de lisière proches des terres anthropisées). Cela suggère que le signal peut indiquer un degré de dégradation dans une certaine mesure, et pas seulement la présence de dégradation. Dans l'ensemble, ces différences étaient plus prononcées à la fin de la saison sèche qu'au début.

Comme le CWC et le MSI sont conçus pour être liés à la teneur en eau, les résultats suggèrent une teneur réduite en humidité des feuilles dans les forêts de lisière et le couvert forestier agroforestier par rapport au couvert forestier dense. Les séries temporelles dans les pixels de transect suggèrent que les forêts de lisière montrent des signes d'un gradient de teneur en eau de la canopée, avec un feuillage de canopée plus sec dans la partie la plus proche de la zone anthropisée (cultures, routes, surfaces ouvertes) et une teneur en eau plus élevée et une surface foliaire plus élevée vers le noyau du massif forestier.

Il ressort de notre étude que la surface foliaire n'est pas le seul paramètre qui caractérise la dégradation, et que le stress hydrique dû à l'effet de bord permet de détecter les processus de dégradation. Au cœur de la saison sèche (janvier/février), le comportement hydrique du feuillage des 4 couverts arborés (systèmes agroforestiers, plantations d'arbres, forêts denses et forêts dégradées) est particulièrement distinct.

### **3.5. Détection des forêts dégradées à partir des variables biophysiques au niveau du pixel et de son voisinage**

Dans cette section, nous explorons une méthode non usuelle pour détecter des forêts dégradées avec l'imagerie satellite optique, à travers des indices biophysiques dérivés des réflectances Sentinel-2 et le voisinage spatial.

Globalement, la majorité des méthodes de détection de dégradation par télédétection optique repose sur une analyse pixellaire, c'est-à-dire que chaque pixel est traité indépendamment de ses voisins. Cependant, comme vu dans l'état de l'art, d'autres méthodes s'appuient sur la prise en compte du contexte spatial. L'enjeu de ce chapitre de thèse sera de s'appuyer sur la sensibilité au degré de dégradation des variables biophysiques LAI, CWC et MSI, et d'introduire la **dimension spatiale dans le voisinage pixellaire**, à travers l'analyse d'une fenêtre de voisinage glissante pour prendre en compte l'information contextuelle comme le ferait un opérateur humain. L'objectif est d'établir un modèle semi-automatisé nécessitant un faible coût de photo-interprétation de la part de l'équipe d'opérateurs dans le projet OCS en Guinée.

Les résultats précédents indiquent que diverses classes de forêts différant par leur degré de dégradation peuvent présenter des différences dans les séries temporelles MSI, CWC et LAI. Les bandes brutes Sentinel-2 à elles seules ne pouvaient pas permettre la détection des forêts perturbées, mais la classification était fortement améliorée lorsque les séries temporelles MSI, CWC et LAI étaient empilées aux bandes brutes et utilisées comme données d'entrée pour les classifications. Deux types de stratégies de classification sont testés, tous deux basés sur l'algorithme Random Forest, sur les mêmes jeux de données d'apprentissage et de validation. La première stratégie est une classification standard basée sur les pixels, où chaque pixel est classé indépendamment de ses voisins. La seconde stratégie prend en compte les 13x13-voisins autour de chaque pixel, dans le but de considérer le contexte comme le ferait un opérateur humain dans les méthodes de photo-interprétation.

### **3.5.1. Méthode basée sur le pixel indépendamment de son voisinage**

La première méthode est une méthode standard ; elle applique l'algorithme Random Forest à l'échelle du pixel. Les bandes brutes Sentinel-2, l'indice de stress hydrique (MSI), l'indice de surface foliaire (LAI) et les indices de teneur en eau de la canopée (CWC) dérivés des bandes brutes sont empilés dans un seul raster « variables ». D'autre part, une couche additionnelle « réponse » est établie où chacun des pixels présente un des 3 labels (forêt dense, forêt dégradée, autre) attribué par photo-interprétation de l'image Sentinel-2. Les deux rasters « variables » et « réponse » sont ensuite joints spatialement avant d'être divisés en deux jeux de données : l'un pour l'entraînement, l'autre pour la validation.

Pour ce faire, des parcelles carrées sont sélectionnées aléatoirement dans l'image, pour être utilisées comme données d'apprentissage. La taille des parcelles d'entraînement est augmentée à chaque test pour comprendre la quantité de données photo-interprétées nécessaires pour classer l'image finale. La taille cumulée des parcelles varie de 1,6% à 25,8% de la surface de l'image (respectivement environ 60 carrés de 1x1 km et 40 carrés de 4x4 km). Le reste des pixels est utilisé pour l'inférence et la validation du modèle. En outre, un tampon de 10 pixels est configuré sur chacune des parcelles pour supprimer les pixels de bordure, de sorte que les pixels de validation ne peuvent pas être contigus aux pixels d'apprentissage, et empêcher l'autocorrélation spatiale entre les données d'apprentissage et de validation (Fig. 39).




Figure 39 : exemple de parcelles carrées sélectionnées aléatoirement sur l'image pour l'entraînement du modèle. Les pixels d'apprentissage sont en gris foncé ; les pixels de validation en gris clair et les pixels noirs dans les zones tampons (10 pixels) sont supprimés pour éviter l'autocorrélation spatiale entre l'apprentissage et la validation.

La conversion en données tabulaires est appliquée d'une part, sur les parcelles d'entraînement et d'autre part, sur les pixels de validation, de sorte que chaque ligne d'un jeu de données correspond à un pixel et chaque colonne correspond à sa valeur radiométrique dans un canal (fig. 40).

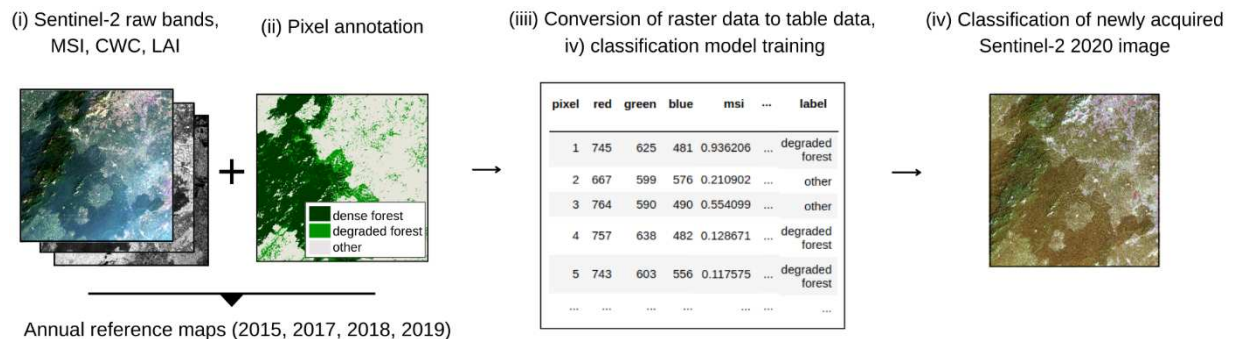


Figure 40 : (i) Calcul des indices MSI, LAI et CWC à partir des bandes Sentinel-2 brutes ; (ii) annotation de chaque pixel (forêt dense, forêt dégradée, autre), et séparation en jeux de données d'entraînement et de validation ; (iii) Conversion des données images en tableau ; entraînement du modèle RF (iv) Classification de l'image 2020.

### 3.5.2. Méthode basée sur le voisinage spatial du pixel

Une autre procédure a été considérée en tenant compte du contexte, afin d'imiter le fait que l'opérateur de photo-interprétation considère le voisinage du pixel tout en cartographiant la forêt dégradée. Les données sont divisées en 2 jeux de données disjoints, en faisant appel à la même procédure de parcelles carrées sélectionnées au hasard pour l'entraînement du modèle, tout en supprimant les pixels tampons. Une fenêtre glissante a été appliquée sur les 2 jeux de données pour extraire les valeurs des pixels voisins. Différentes tailles de fenêtres glissantes ont été testées. Une meilleure classification des pixels

de la forêt dégradée a été atteinte avec une fenêtre glissante de 13 \* 13 pixels appliquée sur les données d'apprentissage. Pour chaque fenêtre, les valeurs du pixel central et de ses voisins ont été extraites dans une table. Cette étape est répétée sur les dix bandes brutes (B2 à B8A, B11 et B12) et les bandes supplémentaires MSI, CWC, LAI, offrant 2197 variables pour un pixel d'intérêt dans notre modèle.

La même procédure de classification Random Forest est appliquée ici, en ajoutant les valeurs des pixels voisins comme nouvelles variables (fig. 41).

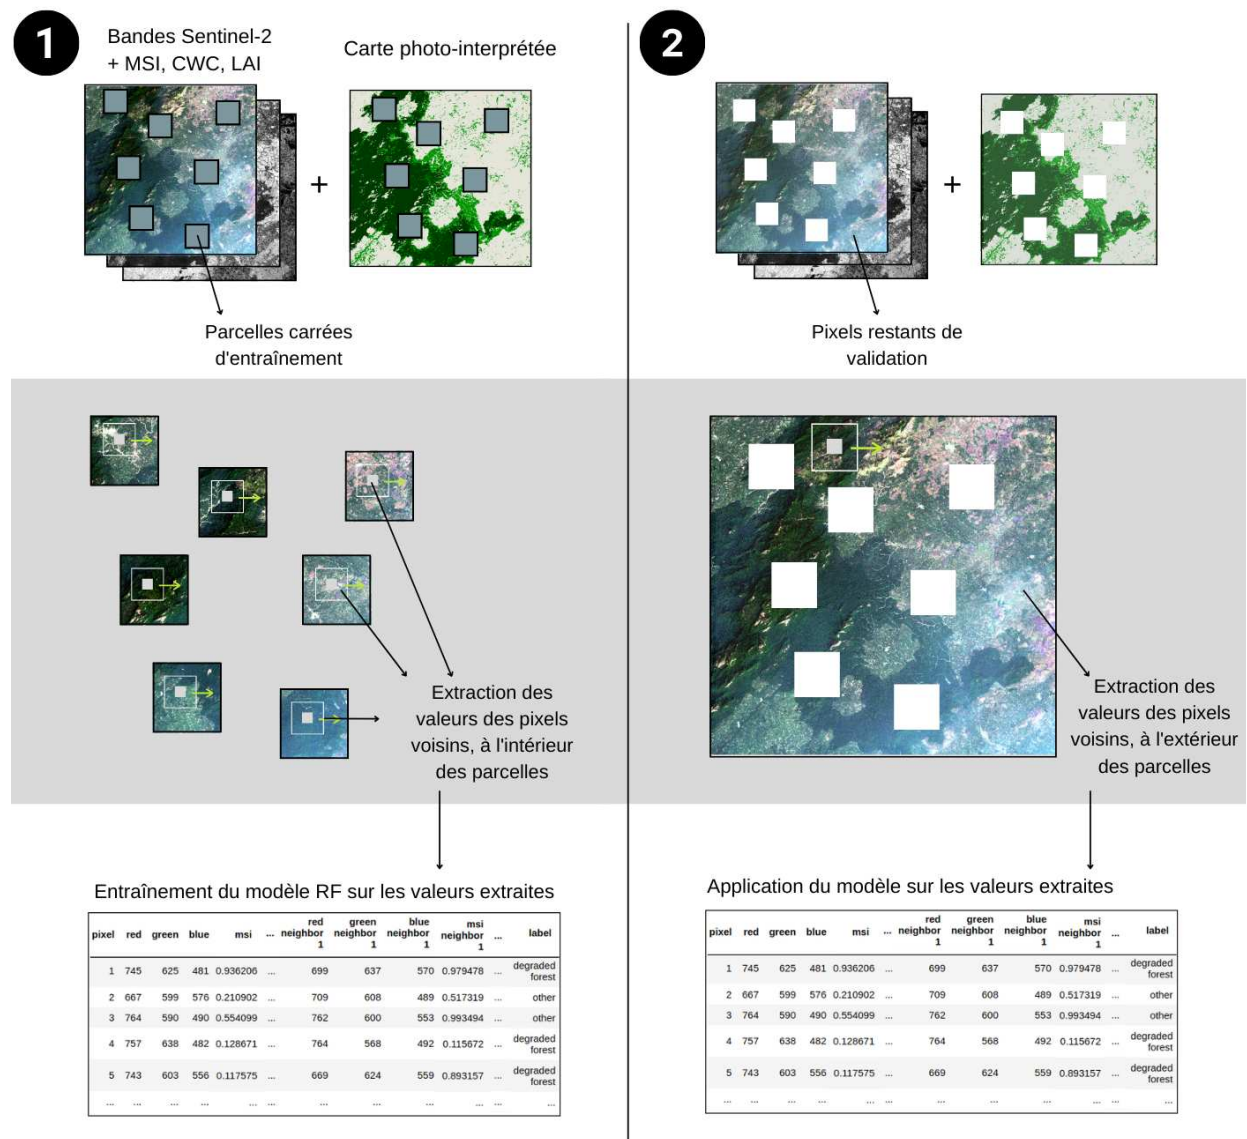


Figure 41 : méthode basée sur les pixels voisins. (i) Dérivation du MSI, du LAI et du CWC à partir des bandes Sentinel-2; combinaison de toutes les bandes en un raster ; (ii) production de la carte photo-interprétée (forêt dense, forêt dégradée, autre), puis extraction des jeux de données d'entraînement (colonne gauche) ; (iii) extraction des pixels voisins par une fenêtre glissante, (iv) conversion des données matricielles en données tabulaires avant entraînement du modèle ; application du modèle sur le reste de l'image (colonne droite) (v) validation du résultat de classification.

### 3.5.3. Évaluation du besoin de photo-interprétation pour la mise à jour de la carte dégradée 2020

Afin de s'affranchir au maximum de la photo-interprétation dans la mise à jour de la carte dégradée 2020, plusieurs approches seront abordées tout en évaluant l'apport du voisinage pixellaire.

L'objet de cette section sera de tester si la connaissance préalable des cartes 2015/2017/2018 et 2019 et/ou celle d'une partie des données de 2020 sont nécessaires pour le modèle de classification RF pour classer la carte des forêts dégradées de 2020 avec de bons résultats (précision globale > 85%). Les résultats issus des 2 méthodes standard et voisinage pixellaire seront comparés (fig.42).

- a) Premièrement, la classification de la carte 2020 est examinée lorsque l'entraînement du modèle a été effectuée sur la carte 2015 photo-interprétée uniquement, afin de vérifier la capacité des méthodes à être transférées d'une année à l'autre.
- b) Deuxièmement, nous étudions le cas où les 4 cartes photo-interprétées (2015, 2017, 2018, 2019) sont utilisées dans les données d'entraînement et si la proportion de données de l'image 2020 à photo-interpréter est nécessaire pour produire la carte forestière 2020.
- c) Troisièmement, la classification des données 2020 sans entraînement autre que les données photo-interprétées à partir de l'image 2020 est explorée.
- d) Enfin, les deux méthodes de classification ont été testées sur une scène inconnue du modèle, située en dehors de la zone d'étude. Pour ce faire, la même procédure de photo-interprétation et la même labellisation des pixels ont été réalisées sur le mont Nimba (7 ° 35'45.2 "N, 8 ° 26'08.9" W), une zone forestière de montagne à l'extrémité sud de la Guinée. Des modèles ont été entraînés sur des scènes de Ziama acquises en 2020 et nous avons examiné la quantité de données photo-interprétées de la scène de Nimba devant être incorporées dans l'ensemble de données d'entraînement.

Ces tests sont synthétisés en figure 42. Dans les 4 cas, l'apprentissage du modèle a été effectué sur des pixels sélectionnés au hasard pour obtenir des exemples d'apprentissage dans différentes conditions radiométriques pour la généralisation et la représentativité du modèle.




Figure 42 : Tests sur le pourcentage de photo-interprétation requis sur des données antérieures à 2020 et/ou des données de 2020 pour classer la forêt dégradée de 2020. a) Classification 2020 à partir de la donnée 2015, avec et sans contribution de 2020 dans les données d'entraînement. b) Classification 2020 à partir des 4 données annuelles antérieures, avec et sans contribution de 2020 dans les données d'entraînement. c) Classification des données 2020 sans entraînement autre que les données photo-interprétées de l'image 2020 elle-même. d) Classification d'une nouvelle région, Nimba, avec et sans contribution de la donnée Nimba dans les données d'entraînement. Les deux méthodes, basées sur les pixels standard et les pixels voisins, sont testées. Dans chaque cas, les pixels d'entraînement sont choisis au hasard.

Les résultats du premier test de classification de l'image Ziama 2020, i.e. lorsque l'entraînement du modèle a été effectué sur la carte 2015 photo-interprétée uniquement, sont présentés dans le tableau 5. Premièrement, les résultats montrent que lorsque les modèles sont entraînés uniquement sur les données de 2015, les deux méthodes ne permettent pas de classer l'image Ziama de 2020 (OA = 0,534 et 0,561 pour les méthodes avec et sans contexte respectivement).

Ensuite, lors de l'incorporation de données photo-interprétées de l'image 2020 dans l'ensemble de données d'entraînement, le modèle basé sur les pixels voisins montre des performances améliorées par rapport au modèle basé sur les pixels. La stratégie pixels-voisins permet l'identification des forêts dégradées avec très peu de photo-interprétation des données 2020. Avec seulement 1,6 % des données photo-interprétées des données 2020, l'algorithme atteint une précision globale supérieure à 89% lorsque



le contexte est pris en compte (contre 86,7% quand il n'est pas pris en compte). De plus, les précisions producteur et utilisateur de la classe de « forêt dégradée » augmentent de 0 à 0,581 et 0,658 respectivement. Lorsque les informations contextuelles sont considérées, cette augmentation est plus élevée que pour les classes « forêt dense » et « autre », suggérant que l'augmentation de l'OA est portée par l'amélioration de la détection de la forêt dégradée.

Les images de classification obtenues avec la méthode des pixels voisins sont affichées lorsque 0 %, 1,6 % et 25,8 % des données 2020 sont jointes aux données 2015 et utilisées comme données d'apprentissage pour la classification (Fig. 43).




Figure 43 : Les images de classification obtenues avec la méthode des pixels voisins sont affichées lorsque 0%, 1.6% et 25.8% des données 2020 S2 sont jointes aux données 2015 et utilisées comme entrée pour la classification.

Dans le deuxième test, les modèles sont entraînés sur des cartes annuelles des années 2015, 2017, 2018 et 2019. Les deux méthodes ne permettent pas de classifier l'image Ziama 2020 si une petite quantité de données 2020 n'est pas ajoutée dans l'ensemble de données d'entraînement (tableau 6). L'échec des modèles pluriannuels peut s'expliquer par les conditions climatiques différentes d'une année à l'autre, ce qui empêche les modèles de généraliser. Avec 1,6% des données 2020 incorporées dans l'ensemble de données d'entraînement, la méthode basée sur les pixels voisins montre une précision globale > 85% (fig.43).

Dans le troisième test, la classification de l'image Ziama 2020 a été testée sans aucune connaissance préalable des cartes annuelles précédentes. La quantité de données photo-interprétées de l'image 2020 requises dans l'ensemble de données d'entraînement a été examinée (tableau 7). La classification basée sur les pixels voisins montre de meilleurs scores de performance que la classification basée sur les pixels, avec une précision globale supérieure à 85% avec seulement 1,6% de photo-interprétation des données 2020 dans l'ensemble de données d'entraînement (tableau 7 et fig.44).

Par ailleurs, l'image S2 de 2015 est plus antérieure dans la saison sèche que les images de référence des autres années (décembre 2015 vs. février 2017, février 2018, janvier 2019 et février 2020). Les séries temporelles des indices CWC, LAI et MSI ont montré une meilleure séparabilité entre les différentes classes en février qu'en décembre, i.e. tard dans la saison sèche. Il convenait donc de tester si une image de début de saison d'une année différente montrait des résultats similaires. Une autre série de tests a été effectuée avec une image acquise en décembre 2019 ; les résultats montrent des performances similaires à celles de la fin de saison (non montrés ici).

En outre, des tests supplémentaires avec des buffers plus larges ont été effectués pour s'assurer qu'il n'y ait pas de fuite des données d'entraînement dans les données de validation. Nous avons constaté que les zones tampons plus grandes (1,5 km au lieu de 100 m) n'influent pas sur les conclusions de l'étude.

Tableau 5 : Statistiques de l'évaluation des deux méthodes de classification entraînées sur l'année 2015 et appliquées sur l'année 2020. Les indicateurs d'évaluation du modèle incluent la précision globale (OA) pour la classification globale et les précisions utilisateur et producteur pour chaque classe.

| Contribution of |              |                 | Overall accuracy |            | Producer's accuracy 'dense forest' |            | User's accuracy 'dense forest' |            | Producer's acc. 'degraded forest' |            | User's acc. 'degraded forest' |            | Producer's acc. 'Other' |            | User's accuracy 'Other' |            |
|-----------------|--------------|-----------------|------------------|------------|------------------------------------|------------|--------------------------------|------------|-----------------------------------|------------|-------------------------------|------------|-------------------------|------------|-------------------------|------------|
| 2015            | 2020         | % of total area | context          | no context | context                            | no context | context                        | no context | context                           | no context | context                       | no context | context                 | no context | context                 | no context |
| 100%            | 0            | 0%              | 0.534            | 0.561      | 0.002                              | 0.081      | 0.991                          | 0.991      | 0.000                             | 0.000      | 0.000                         | 0.291      | 1.000                   | 1.000      | 0.534                   | 0.548      |
| 100%            | 1 x 1 km     | 1.59%           | 0.897            | 0.867      | 0.939                              | 0.918      | 0.900                          | 0.850      | 0.581                             | 0.469      | 0.658                         | 0.564      | 0.950                   | 0.935      | 0.947                   | 0.942      |
| 100%            | 1.5 x 1.5 km | 4.09%           | 0.909            | 0.878      | 0.929                              | 0.880      | 0.922                          | 0.894      | 0.672                             | 0.624      | 0.690                         | 0.586      | 0.957                   | 0.941      | 0.954                   | 0.948      |
| 100%            | 2 x 2 km     | 7.50%           | 0.907            | 0.881      | 0.911                              | 0.884      | 0.926                          | 0.891      | 0.666                             | 0.563      | 0.682                         | 0.609      | 0.965                   | 0.958      | 0.950                   | 0.936      |
| 100%            | 2.5 x 2.5 km | 12.63%          | 0.912            | 0.882      | 0.962                              | 0.947      | 0.900                          | 0.844      | 0.599                             | 0.475      | 0.746                         | 0.657      | 0.959                   | 0.943      | 0.952                   | 0.947      |
| 100%            | 3 x 3 km     | 17.85%          | 0.915            | 0.886      | 0.934                              | 0.902      | 0.921                          | 0.884      | 0.655                             | 0.547      | 0.721                         | 0.631      | 0.968                   | 0.960      | 0.954                   | 0.941      |
| 100%            | 3.5 x 3.5 km | 24.65%          | 0.913            | 0.881      | 0.932                              | 0.890      | 0.929                          | 0.894      | 0.673                             | 0.580      | 0.711                         | 0.610      | 0.962                   | 0.953      | 0.952                   | 0.939      |
| 100%            | 4 x 4 km     | 25.80%          | 0.910            | 0.881      | 0.965                              | 0.939      | 0.885                          | 0.844      | 0.589                             | 0.487      | 0.763                         | 0.670      | 0.959                   | 0.947      | 0.955                   | 0.946      |

Tableau 6 : Statistiques de l'évaluation des deux méthodes de classification entraînées sur les années 2015/2017/2018/2019 et appliquées sur l'année 2020.

| Contribution of |              | Overall accuracy |            | Producer's accuracy 'dense forest' |            | User's accuracy 'dense forest' |            | Producer's accuracy 'degraded forest' |            | User's accuracy 'degraded forest' |            | Producer's accuracy 'Other' |            | User's accuracy 'Other' |            |
|-----------------|--------------|------------------|------------|------------------------------------|------------|--------------------------------|------------|---------------------------------------|------------|-----------------------------------|------------|-----------------------------|------------|-------------------------|------------|
| 2015/17/18/19   | 2020         | context          | no context | context                            | no context | context                        | no context | context                               | no context | context                           | no context | context                     | no context | context                 | no context |
| 2 x 2 km        | 0            | 0.332            | 0.333      | 1.000                              | 1.000      | 0.332                          | 0.332      | 0.000                                 | 0.000      | 0.000                             | 0.000      | 0.000                       | 0.000      | 0.000                   | 1.000      |
| 1 x 1 km        | 1 x 1 km     | 0.897            | 0.860      | 0.925                              | 0.892      | 0.908                          | 0.853      | 0.584                                 | 0.460      | 0.650                             | 0.526      | 0.957                       | 0.940      | 0.945                   | 0.937      |
| 1.5 x 1.5 km    | 1.5 x 1.5 km | 0.908            | 0.873      | 0.917                              | 0.859      | 0.930                          | 0.905      | 0.678                                 | 0.623      | 0.679                             | 0.564      | 0.960                       | 0.947      | 0.952                   | 0.941      |
| 2 x 2 km        | 2 x 2 km     | 0.908            | 0.875      | 0.901                              | 0.861      | 0.940                          | 0.902      | 0.684                                 | 0.574      | 0.673                             | 0.573      | 0.968                       | 0.959      | 0.947                   | 0.932      |
| 2.5 x 2.5 km    | 2.5 x 2.5 km | 0.912            | 0.878      | 0.951                              | 0.927      | 0.911                          | 0.853      | 0.608                                 | 0.468      | 0.732                             | 0.621      | 0.963                       | 0.949      | 0.948                   | 0.940      |

La comparaison des deux méthodes de classification avec la carte photo-interprétée est présentée en figure 44. L'effet "en pointillé" de la méthode basée sur le pixel est dû à la fausse détection de la forêt dégradée et montre les limites de la méthode (zoom a). Classiquement, cet effet est gommé par une phase de tamisage dans les projets de cartographie d'OCS avant la phase de correction thématique.

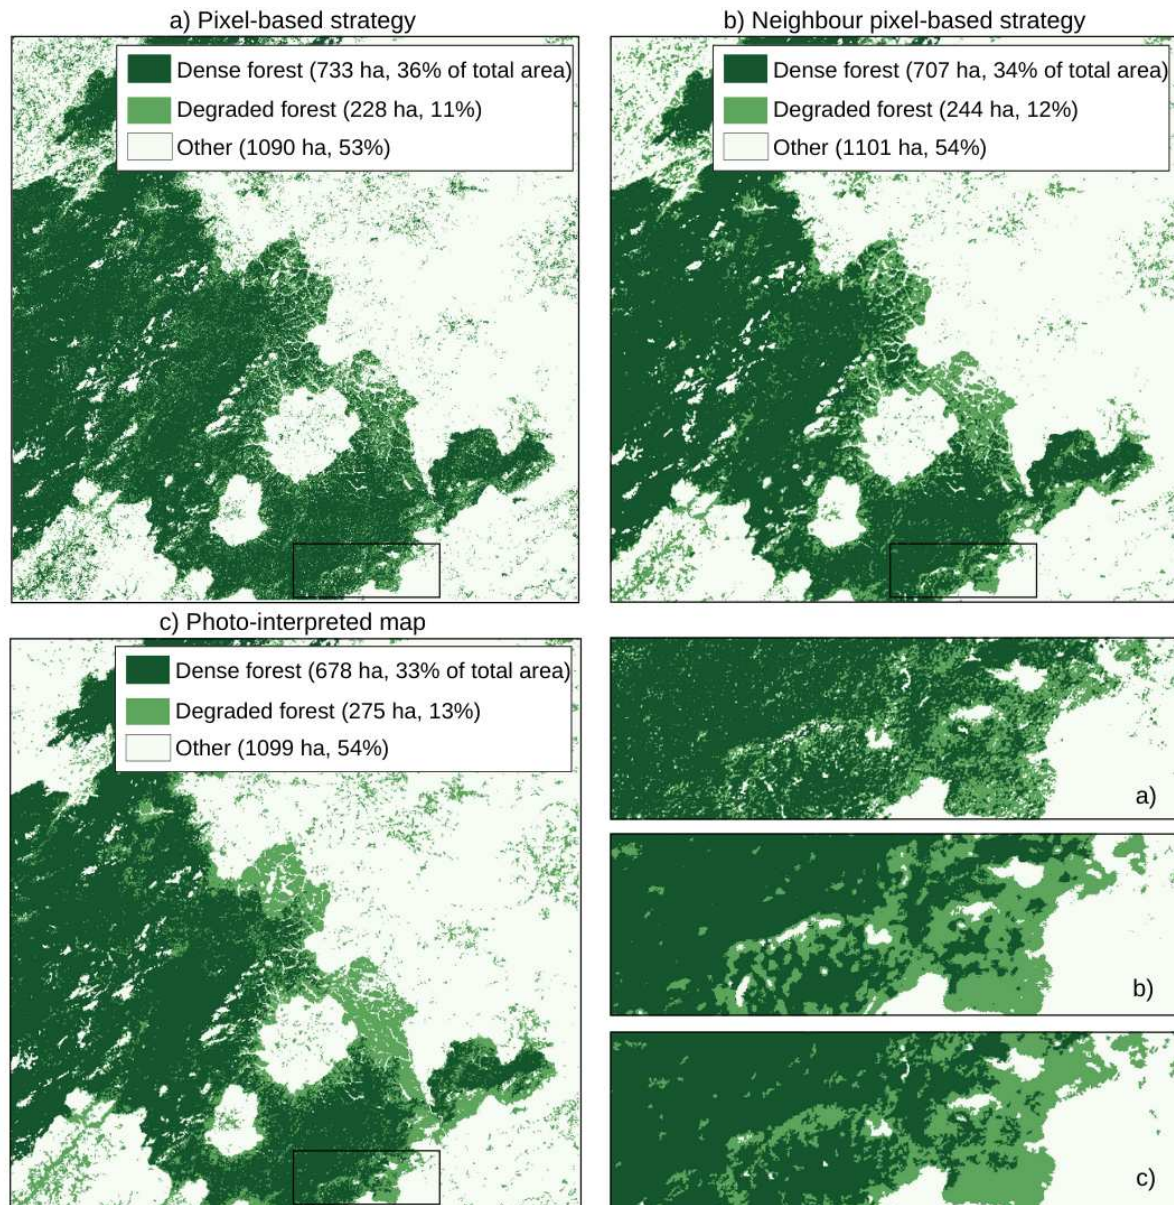


Figure 44 : comparaison des deux méthodes de classification avec la carte photo-interprétée (c) : a) méthodes basées sur les pixels (OA = 0.867) et b) méthodes basées sur les pixels voisins (OA= 0.896). Les résultats sont présentés avec 1,6 % (c'est-à-dire, parcelles carrées de 1 x 1 km) des données photo-interprétées de l'image S2 de 2020 utilisées comme données d'entraînement.

Les résultats montrent que la photo-interprétation des images acquises les années précédentes n'est pas nécessaire à la prédiction d'une nouvelle image. La photo-interprétation de seulement 1,6 % (c'est-à-dire environ 60 parcelles carrées de 1\*1 km) de l'image de 2020 permet un entraînement suffisant du modèle pour des métriques satisfaisantes (OA > 85 %) et une meilleure cartographie des forêts dégradées (Fig.

44). De plus, les précisions utilisateurs suggèrent que 65,5% de la forêt dégradée et 94,8% de la forêt dense ont été détectées avec précision avec la méthode du voisinage pixellaire.

Enfin, les deux méthodes de classification sont testées sur une zone inconnue des modèles, le mont Nimba. Le jeu de données d'entraînement est constitué à la fois d'une image acquise sur Zياما et d'une portion d'image acquise sur Nimba. La quantité de données photo-interprétées de la scène Nimba est augmentée à chaque test. Les deux méthodes - avec et sans voisinage pixellaire – ne parviennent pas à classer l'image Nimba lorsque l'entraînement est effectué sur Zياما seul. Les résultats de classification s'améliorent sur Nimba si le modèle s'entraîne sur cette nouvelle zone. La méthode basée sur les pixels voisins atteint une précision globale supérieure à 84% avec 1,3% de données photo-interprétées de la scène Nimba (contre 82,7% pour la méthode basée sur le pixel) (tableau 8). Les rendus cartographiques montrent l'apport significatif du voisinage pixellaire dans les performances de classification (fig. 45). Cela suggère que la photo-interprétation d'environ 30 parcelles carrées de 1\*1 km permet la cartographie des forêts dégradées dans une zone inconnue et indique que la méthode est site-dépendant.




Figure 45 : Mont Nimba. A : résultat de classification sans voisinage pixellaire. B : avec voisinage pixellaire. C : composition colorée Sentinel-2.

Tableau 7: Statistiques de l'évaluation des deux méthodes de classification entraînées sur l'année 2020 à Ziama sans aucune connaissance préalable des cartes antérieures.

| Contribution of 2020 |                 | Overall accuracy |            | Producer's accuracy 'dense forest' |            | User's accuracy 'dense forest' |            | Producer's accuracy 'degraded forest' |            | User's accuracy 'degraded forest' |            | Producer's accuracy 'Other' |            | User's accuracy 'Other' |            |
|----------------------|-----------------|------------------|------------|------------------------------------|------------|--------------------------------|------------|---------------------------------------|------------|-----------------------------------|------------|-----------------------------|------------|-------------------------|------------|
| plot size            | % of total area | context          | no context | context                            | no context | context                        | no context | context                               | no context | context                           | no context | context                     | no context | context                 | no context |
| 1 x 1 km             | 1.59%           | 0.896            | 0.867      | 0.939                              | 0.92       | 0.9                            | 0.85       | 0.581                                 | 0.469      | 0.655                             | 0.564      | 0.949                       | 0.935      | 0.948                   | 0.943      |
| 1.5 x 1.5 km         | 4.09%           | 0.909            | 0.878      | 0.929                              | 0.881      | 0.923                          | 0.894      | 0.672                                 | 0.623      | 0.69                              | 0.587      | 0.957                       | 0.942      | 0.954                   | 0.948      |
| 2 x 2 km             | 7.50%           | 0.907            | 0.878      | 0.912                              | 0.881      | 0.925                          | 0.894      | 0.666                                 | 0.623      | 0.682                             | 0.587      | 0.965                       | 0.942      | 0.95                    | 0.948      |
| 2.5 x 2.5 km         | 12.63%          | 0.912            | 0.882      | 0.962                              | 0.947      | 0.9                            | 0.844      | 0.597                                 | 0.447      | 0.748                             | 0.657      | 0.96                        | 0.943      | 0.952                   | 0.947      |
| 3 x 3 km             | 17.85%          | 0.915            | 0.886      | 0.934                              | 0.903      | 0.921                          | 0.884      | 0.656                                 | 0.547      | 0.72                              | 0.633      | 0.967                       | 0.96       | 0.955                   | 0.941      |
| 3.5 x 3.5 km         | 24.65%          | 0.941            | 0.904      | 0.967                              | 0.933      | 0.942                          | 0.896      | 0.735                                 | 0.609      | 0.841                             | 0.719      | 0.978                       | 0.962      | 0.963                   | 0.950      |
| 4 x 4 km             | 25.80%          | 0.91             | 0.881      | 0.965                              | 0.939      | 0.885                          | 0.844      | 0.590                                 | 0.488      | 0.763                             | 0.671      | 0.959                       | 0.948      | 0.956                   | 0.946      |

Tableau 8 : Statistiques de l'évaluation des méthodes de classification entraînées sur l'année 2020 à Ziama et appliquées sur l'année 2020 à Nimba.

| Contribution of |              |                 | Overall accuracy |            | Producer's accuracy 'dense forest' |            | User's accuracy 'dense forest' |            | Producer's acc. 'degraded forest' |            | User's acc. 'degraded forest' |            | Producer's acc. 'Other' |            | User's accuracy 'Other' |            |
|-----------------|--------------|-----------------|------------------|------------|------------------------------------|------------|--------------------------------|------------|-----------------------------------|------------|-------------------------------|------------|-------------------------|------------|-------------------------|------------|
| Ziama           | Nimba        | % of total area | context          | no context | context                            | no context | context                        | no context | context                           | no context | context                       | no context | context                 | no context | context                 | no context |
| 100%            | 0            | 0%              | 0.697            | 0.697      | 0                                  | 0          | 0                              | 1          | 0                                 | 0          | 0                             | 0          | 1                       | 1          | 0.697                   | 0.697      |
| 100%            | 1 x 1 km     | 1.28%           | 0.842            | 0.827      | 0.764                              | 0.697      | 0.893                          | 0.867      | 0.537                             | 0.462      | 0.525                         | 0.496      | 0.926                   | 0.935      | 0.902                   | 0.884      |
| 100%            | 1.5 x 1.5 km | 3.45%           | 0.866            | 0.841      | 0.871                              | 0.786      | 0.857                          | 0.822      | 0.598                             | 0.510      | 0.591                         | 0.537      | 0.923                   | 0.925      | 0.929                   | 0.906      |
| 100%            | 2 x 2 km     | 6.11%           | 0.867            | 0.845      | 0.919                              | 0.861      | 0.804                          | 0.764      | 0.577                             | 0.488      | 0.609                         | 0.555      | 0.917                   | 0.917      | 0.935                   | 0.918      |
| 100%            | 2.5 x 2.5 km | 10.10%          | 0.872            | 0.848      | 0.871                              | 0.815      | 0.870                          | 0.823      | 0.516                             | 0.430      | 0.638                         | 0.576      | 0.948                   | 0.944      | 0.911                   | 0.894      |

En conclusion, les résultats montrent une amélioration significative des scores de performance lorsque les informations contextuelles sont prises en compte. La méthode basée sur les pixels voisins est capable de détecter les forêts dégradées subissant des effets de bordure et celles autour des villages. L'inclusion d'informations contextuelles permet de réduire les faux positifs, qui se traduisent par l'effet pointillé caractéristique de la classification basée sur les pixels (fig. 17).

Dans tous les tests, les précisions utilisateur et producteur de la classe « forêts dégradées » sont systématiquement plus basses que les autres précisions utilisateur et producteur des autres classes, ce qui montre la forte confusion entre les pixels de « forêt dense » et les pixels de « forêt dégradée ». En termes de signal, la prise en compte des voisins améliore la classification notamment en lisière où le modèle apprend à reconnaître les forêts dégradées situées aux interfaces forêt / non-forêt.

La cartographie des forêts dégradées est également permise sans connaissance préalable d'images d'années précédentes au même site avec la méthode contextuelle. En outre, cette approche nécessite une quantité limitée de données photo-interprétées pour produire la carte des forêts dégradées de 2020. Par conséquent, l'utilisation du voisinage spatial comme entrée dans les modèles de classification convient aux praticiens locaux avec un coût de photo-interprétation raisonnable pour produire de bons résultats. Cela prouve la pertinence du contexte lors de la tentative de détection des forêts endommagées dans une cartographie d'OCS.

### **3.6. Conclusion sur l'utilisation des séries temporelles optiques dans la détection des forêts dégradées**

Les séries temporelles fournissent des mesures répétées pour saisir les changements, y compris les perturbations naturelles (par exemple, les incendies, les attaques d'insectes, les changements phénologiques chez la végétation) et anthropiques (par exemple, la déforestation, l'urbanisation). La difficulté de séparer explicitement les signatures spectrales des forêts dégradées de celles des forêts denses est un second obstacle que les séries temporelles peuvent lever.

Nos résultats montrent que les forêts guinéennes présentent de grandes différences dans le domaine spectral du moyen-infrarouge liées à leur état dégradé, évoquant un effet d'humidité. Il est probable que ces comportements spectraux distincts dans les couverts arborés s'expliquent à la fois par la diminution globale du LAI et par les différentes réponses physiologiques de dessiccation des feuilles, en réaction à l'ouverture du couvert supérieur. L'utilisation de série temporelle comme donnée d'entrée dans un modèle Random Forest permet de regrouper les pixels ayant un comportement spectral similaire dans les mesures SMA, MSI ou bien CWC et améliore la cartographie des forêts dégradées, tant sur le plan thématique que sur le plan statistique ( $OA > 0,85$ ), comparé aux classifications mono-dates.

Il ressort de notre étude qu'une détection semi-automatique des forêts dégradées en utilisant la méthode SMA appliquée aux images Sentinel-2 n'est pas pertinente en raison de l'instabilité des valeurs de références choisies, qui varient selon la zone géographique sur laquelle elles sont mesurées. L'instabilité des valeurs de référence est d'autant plus forte que la sélection est faite sur un pixel de 10 m sur 10 m où il est parfois difficile de trouver des occupations du sol totalement homogènes. Ces valeurs de

référence sont aussi sujettes à une part de subjectivité du télédéacteur, ce qui induit des biais additionnels dans une équipe de plusieurs opérateurs.

Les analyses temporelles des indices MSI et biophysiques LAI et CWC montrent une bonne discrimination des forêts dégradées sur les points de contrôles. Les classifications multitemporelles sur les indices MSI, CWC et LAI donne d'aussi bons résultats que les classifications multitemporelles sur les fractions de l'analyse SMA en termes de précision globale et de précisions utilisateur/producteur. L'avantage de cette approche réside dans le choix des ROI (régions d'intérêt) pour l'entraînement du modèle qui sont généralement des séries de polygones. Cela permet de nourrir le modèle avec une grande variété de radiométries pour une seule classe et permet au modèle de généraliser et/ou de prendre en compte les variations radiométriques géographiques que peut présenter une classe donnée. Autre avantage : cette approche est relativement simple et présente des temps de calcul assez rapides. Les calculs des indices MSI, CWC et LAI peuvent par ailleurs être automatisés et la qualité des indices ne dépend pas de l'intervention du télédéacteur. Ceci offre un avantage considérable en projet d'OCS pour un transfert de compétence.

En revanche, les classifications multitemporelles SMA mais aussi sur MSI, CWC, LAI sont visuellement non abouties ; on note une sur-détection importante des forêts dégradées dans la forêt dense, qui prend la forme de pixels mal classés dans le massif. Cet effet « pointillé » requiert systématiquement une phase de tamisage avant la phase de correction des résultats de classifications dans un projet classique d'OCS.

Le recours à l'utilisation du voisinage spatial comme entrée dans les modèles de classification permet d'alléger la phase de tamisage. Les pixels auparavant mal classés et isolés sont mieux détectés grâce à leur voisinage spatial. Cette approche convient particulièrement aux praticiens locaux car elle offre un coût de photo-interprétation très raisonnable (1,6% de la zone à classer, soit environ 60 parcelles carrées de 1\*1 km) pour produire de bons résultats selon la précision exigée par la méthodologie VCS. L'approche impliquant l'inclusion de pixels voisins ne permet pas cependant d'entraîner de modèle RF sur plus de 2 images Sentinel de la taille de Ziama (4600 x 4600 pixels) sans recourir à une puissance de calcul excessive. Cet inconvénient empêche le modèle de s'entraîner sur un large panel d'images et par conséquent, d'être capable de classer une nouvelle image Sentinel-2 à une nouvelle date ou bien sur une nouvelle zone, sans s'être entraîné dessus au préalable.

Le présent chapitre a exploré le contenu physique du signal de télédétection au niveau des pixels de forêts en fonction du degré de dégradation, et au niveau de son voisinage. Une méthode de classification en a été déduite. Elle s'est montrée efficace mais nécessite un réapprentissage, certes limité, pour chaque nouvelle année ou chaque nouvelle zone. L'apprentissage en profondeur ou deep learning, et une autre stratégie tenant compte du contexte autant que de la radiométrie du pixel s'avère un outil remarquable dans de nombreux domaines de traitement d'images. Ainsi, une telle approche va être explorée dans le prochain chapitre, dans l'objectif de pouvoir s'affranchir du besoin de réapprentissage. Notons que les résultats des méthodes issues du chapitre 2 (par photo-interprétation), celles de ce chapitre (Random Forest) et du chapitre 4 (réseau de neurones) seront toutes comparées à un même jeu de données indépendant au chapitre 5.





## Chapitre 4

# Détection des forêts dégradées à partir des sciences participatives et de l'apprentissage profond

Les résultats du chapitre 3 indiquent que la prise en compte du contexte spatial de chaque pixel dans une classification Random Forest améliore la détection des forêts dégradées. L'objectif de ce chapitre est d'évaluer si l'apprentissage profond, connu pour sa capacité à reconnaître des objets et donc le contexte spatial, peut tout autant améliorer la détection des forêts dégradées et supprimer le besoin de réentraînement pour chaque nouveau site, principal défaut de la méthode présentée au chapitre 3. Dans cette étude, nous tentons de cartographier la forêt dégradée en Guinée, en utilisant une méthode aussi transférable que possible, c'est-à-dire qui peut s'appliquer d'une année à une autre et d'un massif à un autre. La méthode ne devra pas requérir de photo-interprétation des nouvelles images acquises en Guinée forestière en 2021 pour l'extension du projet ZAEG porté par IGN FI.

### 4.1. Introduction

#### 4.1.1. Problématique

Les protocoles de cartographie des forêts dégradées reposent actuellement sur la digitalisation manuelle, ce qui ne convient pas aux projets d'occupation du sol à des échelles nationales. Dans le chapitre 3, les approches semi-automatisées Random Forest ne produisent pas de cartes de forêts dégradées aussi précises qu'un examen réalisé par un expert en photo-interprétation ; une phase de tamisage et de correction manuelle est toujours nécessaire. Les résultats du chapitre 3 ont cependant montré qu'une prise en compte du contexte apporte une nette amélioration de la cartographie des forêts dégradées. L'apprentissage en profondeur (aussi appelé apprentissage profond et deep learning en anglais) représente une approche novatrice, en particulier les **réseaux de neurones convolutifs** qui sont capables de considérer le contexte régional dans les phases d'apprentissage et de classification d'image. L'apprentissage des procédures de classification par deep learning (DL) nécessite cependant de très larges jeux de données. Or la disponibilité de données d'entraînement labellisées à grande échelle est limitée. C'est le principal obstacle de l'apprentissage profond en télédétection (Zhu et al., 2017). À l'heure actuelle, les jeux de données d'entraînement labellisés sont rares et leur création est longue. La plupart des données disponibles sont des banques de photographies d'objets comme ImageNet, une base de 14 millions d'images labellisées réparties dans plus de 1000 classes (animaux, fruits etc.). Il existe très peu de données d'images satellites étiquetées accessibles au public : l'exemple le plus connu étant SpaceNet, issu d'une collaboration entre IQT Labs et Maxar, une base de données ouvertes à la résolution spatiale de 30 cm, sur des zones géographiquement diverses, labellisées pour l'extraction automatisée d'empreintes de bâtiment ou du réseau routier (exemples en figure 46).




Figure 46 : exemples d'images SpaceNet labellisées pour l'extraction automatisée d'empreinte de bâtiment. En rouge, le bâti ; en bleu, non bâti.

L'identification et l'annotation précise des objets dans les images d'entraînement sont actuellement un goulot d'étranglement pour de nombreuses utilisations de données satellites. L'identification et la délimitation des classes nécessitent une formation spécialisée, une connaissance approfondie des sujets et des compétences techniques pour annoter les images. La digitalisation est un geste technique difficile car une mauvaise numérisation des pixels génère des confusions entre classes pour les modèles de classification. Le coût de l'investissement dans le personnel spécialisé et le temps nécessaire pour interpréter et annoter les éléments peut être considérable et inaccessible pour les applications d'apprentissage profond avec des images satellites. En outre, les données de télédétection sont géolocalisées, ce qui ajoute un niveau de complexité supplémentaire. C'est pour cette raison que l'apprentissage en profondeur entièrement automatisé et sans expert n'est pas valable pour la télédétection (Zhu et al., 2017 ; Irvin et al., 2020 ; Hua et al., 2022).

#### 4.1.2. Objectifs du chapitre

Les objectifs de ce chapitre sont de :

- i) Enrichir le jeu de données construit dans le chapitre 2 et étiqueté selon 3 classes : forêt dense, forêt dégradée et non-forêt ;
- ii) Adapter un réseau de neurones convolutif (U-Net) existant aux images Sentinel-2 acquises sur nos zones d'étude, dans l'objectif de cartographier les forêts dégradées ;
- iii) Tester les résultats obtenus et les comparer avec ceux de 2 autres réseaux de la littérature (SegNet, ResNet-UNet) ; ces tests peuvent être synthétisés en 5 questions :
  - Q1. Quel est l'impact de la taille du jeu d'entraînement sur les performances de classification ?
  - Q2. Quel modèle produit les meilleures précisions globales ?
  - Q3. Quel est l'impact de la normalisation des données sur les précisions globales ?
  - Q4. Quelle est la capacité de généralisation du modèle choisi sur un nouveau massif forestier ?
  - Q5. Peut-il être performant sur une image acquise une autre année ?
- iv) Valider par les experts en OCS chez IGN FI les cartes produites par le meilleur réseau, à travers une photo-interprétation indépendante de 900 sites échantillonnés aléatoirement.

### 4.1.3. Plan du chapitre

Dans la section 4.2 de ce chapitre, nous introduisons l'état de l'art de l'apprentissage profond en télédétection. La section 4.3 présente les matériels et méthodes du chapitre. Il s'agira de décrire : i) la base de données construite pour la détection des forêts dégradées par la méthode de PI décrite au chapitre 2 ; ii) les concepts d'apprentissage profond et de réseaux neuronaux convolutifs (CNN), avant d'exposer le modèle U-Net utilisé avec l'aide de la science citoyenne ; iii) la comparaison de ce modèle à 2 autres modèles SegNet et ResNet-UNet. Enfin, le protocole de validation des cartographies telle qu'habituellement réalisé au sein d'IGN FI y sera décrit. La section 4.4 détaillera les résultats, la sélection du meilleur modèle ainsi que les résultats de la méthode de validation indépendante par IGN FI des cartes produites par le modèle. Enfin, la section 4.5 synthétise les résultats des travaux utilisant l'apprentissage en profondeur menés dans cette étude. Le flux de travail du chapitre 4 est illustré en figure 47.

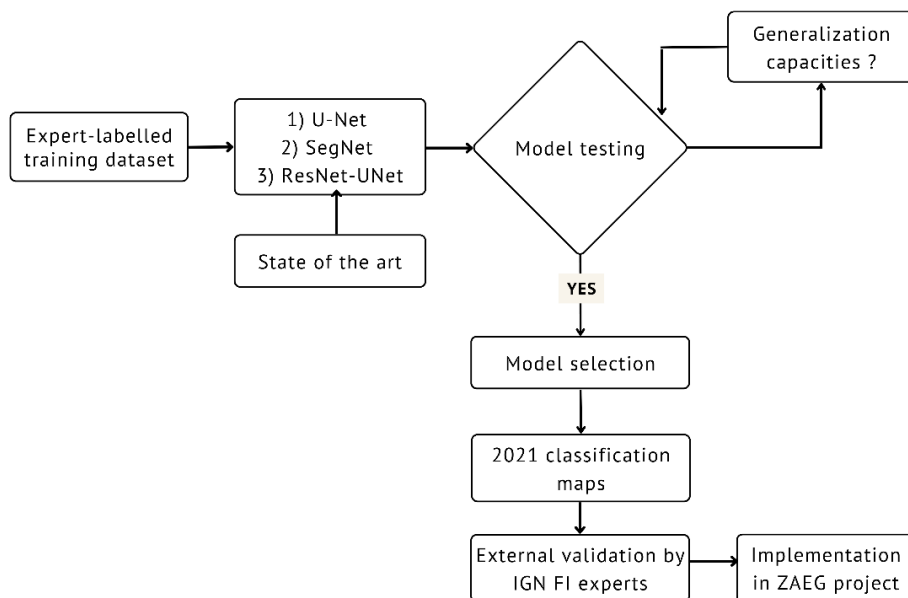


Figure 47 : flux de travail pour le chapitre 4.

## 4.2. Etat de l'art : applications des réseaux de neurones en télédétection

Une revue détaillée des modèles CNN les plus connus est proposée par Zhu et al. (2017). Pour la thèse, nous faisons appel aux réseaux conçus pour la **segmentation sémantique** qui classe chaque pixel d'une image, et dont le fonctionnement sera décrit en 4.3.2. La sortie elle-même est une image, de même taille que l'image d'entrée, dans laquelle chaque pixel est classé dans une classe particulière. La segmentation d'images médicales et d'images de télédétection sont deux cas typiques de classification au pixel près. En segmentation d'images médicales, l'objectif est de classer chaque pixel d'une image (IRM etc.) selon le type de tissu organique en vue de poser un diagnostic (Rundo et al., 2017 ; Qayyum et al., 2017). Les réseaux de neurones convolutifs se sont également révélés être des modèles puissants

pour résoudre les problèmes de classification par pixel dans le domaine du traitement d'images de télédétection (Han et al., 2012 ; Zhang et al., 2016) comme c'est le cas de la cartographie de l'occupation des sols à l'aide d'images satellites. Les réseaux CNN ont été utilisés avec succès dans différentes tâches de classification en télédétection, telles que la segmentation des bâtiments, des nuages, de l'eau et l'utilisation des terres (Zhang et al., 2016). Les CNN pour la segmentation sémantique tels que U-Net et SegNet, ont été adaptés à tout type de données de télédétection ces cinq dernières années : LiDAR, drones aéroportés, images radar, images optiques hyperspectrales, multispectrales etc. Quelques études sont citées dans cette section.

- Avec le **LiDAR** : Lambers et al. (2019) développent une méthodologie pour la détection automatisée d'objets archéologiques aux Pays-Bas. La science citoyenne est mobilisée dans le but de générer un jeu d'entraînement pour les réseaux de neurones convolutifs.
- Avec des **orthophotographies aériennes** : Cao & Zhang (2020) classifient les espèces d'arbres forestiers sur des **orthophotos aéroportées** dans le Guangxi, en Chine. Les auteurs utilisent une combinaison du réseau U-Net et du réseau ResNet. Les résultats sont comparés à ceux du réseau U-Net non combiné et atteignent une précision de classification plus élevée (87 %). Hamdi et al. (2019) détectent et cartographient les chablis en Bavière. Le réseau est basé sur une architecture U-Net modifiée entraînée sur des **orthophotographies aériennes multispectrales** de résolution spatiale de 0,2 m et qui présentaient des bandes RVB et PIR. La précision globale atteinte par les auteurs était de 92 %.
- Avec les **images satellites à très haute résolution spatiale** : les réseaux de neurones convolutifs ont permis la détection et le comptage automatique d'éléphants sur des images Worldview-3 et 4 dans un écosystème de savane boisée en Afrique du Sud, avec une précision aussi élevée que les capacités de détection humaines (Duporge et al., 2020). Zhang et al. (2018) produisent une cartographie de la ville de Pékin avec les images WorldView-2 et WorldView-3 à une résolution spatiale de 0,5 et 0,3 m respectivement. Au Brésil, dans la forêt tropicale atlantique, les mêmes imageries Worldview sont combinées à des photographies aériennes géoréférencées de 1962 pour cartographier le couvert forestier et ses changements, ainsi que pour détecter automatiquement deux espèces d'arbres, *Cecropia hololeuca* et *Tibouchina pulchra* (Wagner et al., 2020).
- Avec les **images satellites à haute résolution spatiale** : dans les travaux de Knopp et al. (2020), la segmentation des zones brûlées est permise en utilisant l'imagerie mono-date **Sentinel-2**. Les auteurs ont notamment créé et labellisé un nouveau jeu de données d'entraînement et de validation, utilisé par la suite par le réseau U-Net. Yan et al. (2019) présentent une classification des glaciers à partir de **Sentinel-2** en adaptant aussi un réseau de neurones convolutifs de segmentation sémantique.
- En utilisant la **dimension temporelle** : Stoian et al. (2019) produisent des cartes d'occupation du sol dans un contexte opérationnel avec des séries temporelles **Sentinel-2** à l'échelle de la France et une architecture dérivée de U-Net développée par les auteurs. Ces derniers concluent notamment que les réseaux de neurones entièrement convolutifs peuvent donner de meilleurs

résultats par rapport aux classifieurs Random Forest basés sur le pixel malgré un coût de calcul élevé pour les systèmes opérationnels.

- En **fusionnant les capteurs optique et radar** : dans l'étude de Emek et Demir (2020), U-Net permet la détection de bâtiments à Rotterdam, aux Pays-Bas, à partir de la fusion d'images radar **Sentinel 1** et optiques **Sentinel-2**, avec une précision de 81 %.
- Pour la détection de la **déforestation** : dans l'étude présentée par Park et Lee en 2019, les zones de déboisement en Corée sont détectées sur les données **Landsat** (30 m de résolution spatiale) et à l'aide des modèles U-Net et SegNet. Dans les travaux d'Irvin et al. (2020), un modèle d'apprentissage en profondeur classe les facteurs de perte de forêt primaire en Indonésie à partir d'images **Landsat-8**, comme le remplacement de la forêt primaire par une plantation industrielle ou de la petite agriculture. Ici aussi, les annotations des facteurs de pertes de forêt ont été conduites par des experts photo-interprètes ; elles sont accessibles au public. D'autres nombreuses approches ont été proposées pour détecter la déforestation à l'aide d'architectures CNN (U-Net, SegNet et dérivés) au Brésil (de Bem et al., 2020 ; Ortega Adarme et al., 2020 ; Mareto et al., 2021), en Corée (Lee et al., 2020) avec les données Kompsat-3) ou à des échelles pantropicales (Amérique latine, Afrique et Asie) avec des séries temporelles **Landsat** (Masolele et al., 2021).
- Les recherches combinant CNN et détection de **forêts dégradées** sont plus rares. Dans les forêts de sapins en Sibérie centrale, les images issues de **drones aériens** (UAV) ont permis de détecter les sapins dégradés grâce à la détection d'indicateurs externes liés à l'invasion du scolyte *Polygraphus proximus* (Safonova et al., 2019). Au Brésil, dans la forêt tropicale atlantique, le réseau U-Net permet d'identifier et de différencier les forêts naturelles des plantations d'eucalyptus, puis de détecter les forêts perturbées en localisant l'espèce d'arbre *Cecropia hololeuca*, un indicateur de perturbation des forêts, à partir d'images **WorldView-3**, avec une précision globale supérieure à 95 % et 97 % respectivement, sur une région de 1600 km<sup>2</sup> (Wagner et al., 2020).

A notre connaissance, aucune étude ne fait appel à l'apprentissage profond pour la détection de forêts dégradées sur l'imagerie Sentinel-2.

## 4.3. Matériels et méthodes

### 4.3.1. Construction du jeu de données photo-interprété

Le même jeu de données du chapitre 2 a été utilisé, en ajoutant 5 images supplémentaires acquises en 2020 pour l'entraînement des réseaux de neurones. La photo-interprétation de tuiles temporelles supplémentaires sur les mêmes scènes permet d'offrir au modèle CNN des représentations de forêts dégradées et denses dans des conditions radiométriques et atmosphériques différentes, dans le but

d'améliorer sa généralisation. Au total, ce sont 14 images acquises entre fin 2015 et 2020, dont 10 sur le massif de Ziama et 4 à Diécké, qui ont été photo-interprétées.

Pour la phase de test de classification et d'évaluation des modèles, 3 images ont été choisies en 2021 sur la base de leur couverture nuageuse inférieure à 5 %, une au-dessus de chacun des 3 massifs de Guinée forestière : Ziama, Diécké et le mont Nimba. Aucune image Sentinel-2 de Nimba n'est impliquée dans l'entraînement des modèles afin de tester leur capacité de généralisation. Les dates d'acquisition sont données dans le tableau 9. Les trois modèles sont donc évalués sur des données totalement indépendantes de celles utilisées pour la calibration, soit temporellement, soit spatialement.

Tableau 9 : données images Sentinel-2 photo-interprétées et utilisées pour l'entraînement des modèles CNN ou leur évaluation.

| Massif | Dates d'acquisition de l'image Sentinel-2  | Phase d'implication | Surface totale (km <sup>2</sup> ) |
|--------|--|---------------------|-----------------------------------|
| Ziama  | 03/12/2015<br>05/02/2017<br>27/12/2018<br>07/03/2019<br>06/01/2020,<br>11/01/2020,<br>16/01/2020,<br>21/01/2020<br>05/02/2020,<br>15/02/2020 | <i>Entraînement</i> | 2 1160                            |
|        | 25/01/2021   | <i>Validation</i>   | 2 116                             |
| Diécké | 05/02/2017<br>06/01/2020,<br>15/02/2020,<br>05/02/2020   | <i>Entraînement</i> | 6480                              |
|        | 09/02/2021   | <i>Validation</i>   | 1620                              |
| Nimba  | 25/01/2021   | <i>Validation</i>   | 2400                              |

Au total, 2,7 millions d'hectares ont été étiquetés par photo-interprétation pour être utilisés comme données d'entraînement. Les pixels sont annotés avec les codes : (1) forêt dense, (2) forêt dégradée ou (3) non-forêt. Les pixels non forestiers comprennent les cultures, les villages, les sols nus, les rivières, les zones arbustives et herbacées, les plantations de palmiers et les plantations d'arbres.

Les forêts denses et dégradées ont été délimitées manuellement à l'aide du logiciel de système d'information géographique QGIS et ont été converties en un masque de pixels de 10 mètres sur 10 mètres, sur la résolution de l'imagerie Sentinel-2. L'identification des forêts dégradées a été effectuée à l'aide de la méthode décrite dans le chapitre 2. Le jeu de données photo-interprétées final comprend 10 canaux de Sentinel-2 (bandes 2 à 8A, bandes 11 et 12) de résolution de 10 et 20 mètres et

rééchantillonnées à 10 m. Des canaux supplémentaires sont fournis : MSI, LAI et CWC, comme étudié dans le chapitre 3.

Enfin, le jeu de données est découpé en imagerie de 128 \* 128 pixels. Ces imagerie sont aléatoirement réparties en un jeu de données d'entraînement et un jeu de données de test (70% et 30% respectivement) pour entraîner les modèles (fig. 48).




Figure 48 : Génération des données d'entrées qui comprennent les bandes brutes Sentinel-2, les indices liés à l'humidité (MSI, CWC), l'indice de surface foliaire (LAI), et les cartes photo-interprétées correspondantes.

#### 4.3.2. Les réseaux neuronaux convolutifs (CNN)

Le machine learning est un sous-ensemble de l'intelligence artificielle (fig. 49). L'algorithme apprend à partir de données connues. Les classifications supervisées d'image satellite rencontrées traditionnellement, e.g. les classifieurs Support Vector Machine (SVM), K-Nearest Neighbor, la régression logistique et les algorithmes basés sur les arbres de décision comme Random Forest, appartiennent à ce sous-ensemble.



**L'apprentissage en profondeur**, ou apprentissage profond, est le sous-ensemble suivant du machine learning. Les **réseaux de neurones convolutifs** (Convolutional Neural Networks ou CNN) appartiennent au sous-ensemble du deep learning. Ils visent à résoudre des problèmes de classification en imitant la structure biologique du cerveau. En télédétection, les CNN sont utilisés pour extraire les caractéristiques spectrales et spatiales des objets pour effectuer la classification d'image. Une convolution a pour objectif d'extraire les informations les plus pertinentes d'une image qui constitueront les variables pour l'étape de classification. Un filtre de convolution de taille fixe se déplace et parcourt la totalité de l'image, en effectuant une opération sur les pixels (e.g. extraction de la valeur maximale). C'est donc le principe de convolution qui permet de prendre en compte le contexte spatial d'un pixel comme variable utilisable pour le classer.




Figure 49 : schéma des sous-ensembles de l'intelligence artificielle. Les réseaux de neurones convolutifs (CNN) appartiennent au sous-ensemble du deep learning.

La structure des réseaux neuronaux convolutifs (CNN) est l'un des modèles d'apprentissage profond dont les applications ont été les plus répandues ces dernières années. C'est dans une certaine mesure une simulation du système nerveux visuel (Fukushima, 1980). L'analogie entre un neurone du cerveau humain et un neurone de réseau de neurones convolutifs est schématisée en figure 50. Le concept principal tiré des neurones biologiques est qu'ils prennent en entrée des sorties de plusieurs neurones et produisent une sortie qu'ils peuvent à nouveau amener à d'autres neurones ; ils sont interconnectés pour former des réseaux très complexes. La sortie de chaque neurone dépend d'une moyenne pondérée des entrées, le poids de chaque entrée étant étalonné lors de la phase d'apprentissage.

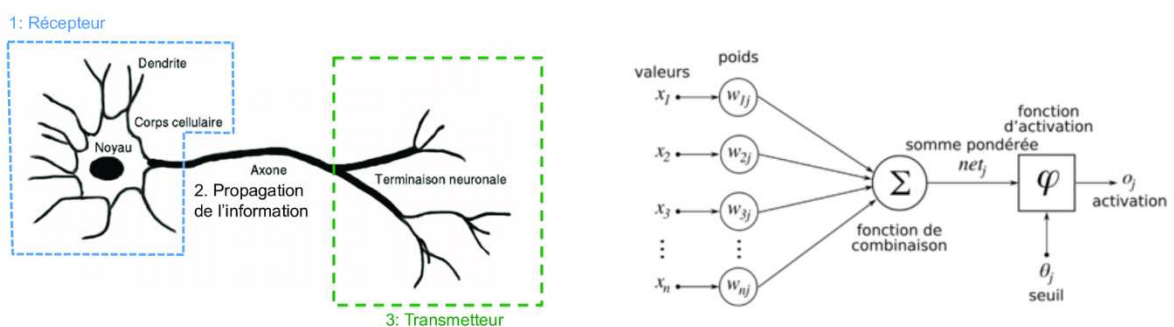


Figure 50 : analogie entre un neurone biologique et un « perceptron » de réseau de neurones convolutifs. Adapté de Hands on Mathematics for Deep Learning (Dawani, 2020).

Mathématiquement, nous pouvons écrire ce neurone comme :

$$y = \begin{cases} 1, & \text{if } \sum_{i=1}^n x_i w_i \geq b \\ 0, & \text{otherwise} \end{cases}$$

Le neurone ou perceptron prend des valeurs comme entrées et chaque entrée est multipliée par un poids. Si la somme des entrées pondérées est supérieure au seuil  $b$ , alors le neurone sort 1, sinon 0. Une fois la somme pondérée effectuée, le résultat est entré dans une fonction non linéaire (fonction d'activation  $\varphi$ ) :

$$y = \varphi \left( \sum_i w_i x_i + b \right)$$

Les neurones d'un réseau de neurones convolutifs sont disposés en plans pour former des couches convolutives, similaire à la distribution des cellules visuelles dans les rétines. Les multiples couches du réseau sont également la raison pour laquelle les CNN sont qualifiés d'architectures d'apprentissage profond (fig. 51). Plus le nombre de couches de neurones est élevé, plus le réseau est « profond ».




Figure 51 : schéma de couches de neurones. Source : Hands on Mathematics for Deep Learning (Dawani).

Mathématiquement, nous pouvons écrire ceci comme suit :

$$h_i^{[1]} = \varphi^{[1]} \left( \sum_j w_{i,j}^{[1]} x_j + b_i^{[1]} \right)$$

$$h_i^{[2]} = \varphi^{[2]} \left( \sum_j w_{i,j}^{[2]} h_j^{[1]} + b_i^{[2]} \right)$$

$$h_i^{[3]} = \varphi^{[3]} \left( \sum_j w_{i,j}^{[3]} h_j^{[2]} + b_i^{[3]} \right)$$

$$y_i = \varphi^{[4]} \left( \sum_j w_{i,j}^{[4]} h_j^{[3]} + b_i^{[4]} \right)$$

Ici,  $h_i^{[l]}$  est une variable issue du  $i^{\text{ème}}$  neurone dans la  $l^{\text{ème}}$  couche,  $\varphi^{[l]}$  est une fonction d'activation pour la  $l^{\text{ème}}$  couche,  $x_j$  est la  $j^{\text{ème}}$  entrée du réseau,  $b_i^{[l]}$  est le biais pour le  $i^{\text{ème}}$  neurone dans la  $l^{\text{ème}}$  couche, et  $w_{i,j}^{[l]}$  est le poids qui relie le  $j^{\text{ème}}$  neurone de la  $l - 1^{\text{ème}}$  couche au  $i^{\text{ème}}$  neurone de la  $l^{\text{ème}}$  couche.

En outre, les réseaux neuronaux convolutifs ne connectent pas tous les neurones des couches successives, mais seulement ceux qui se trouvent dans le voisinage, ce qui permet d'intégrer des

informations contextuelles et de réduire le temps de calcul nécessaire. Cela permet d'extraire les informations régionales contenues dans une partie de l'image, pareil au mécanisme naturel de perception visuelle des êtres humains (Hubel et Wiesel, 1968). Avec un nombre suffisant d'échantillons de données, les réseaux neuronaux convolutifs profonds sont capables de traiter des problèmes visuels complexes.

Deux réseaux CNN sont présentés dans cette section. Le premier est un réseau U-Net, un des réseaux les plus répandus en segmentation sémantique, et dont le développement a pu être assisté par la science citoyenne dans le cadre de la thèse. Le second modèle est le réseau SegNet, alternative souvent comparée à U-Net dans la littérature. Les réseaux de neurones convolutifs U-Net et SegNet sont construits en utilisant Python 3.6.8 grâce aux packages **keras** (<https://github.com/fchollet/keras>) et **TensorFlow** sur un GPU (*Graphics Processing Unit* ou processeur graphique) de Google Colaboratory. Colaboratory est un service cloud, proposé par Google et destiné à la formation et à la recherche dans l'apprentissage automatique. Cette plateforme permet d'entraîner des modèles de Machine Learning directement dans le cloud.

#### 4.3.2.1. Le réseau U-Net par la science citoyenne

Les rôles de la science citoyenne dans les projets d'apprentissage profond résident généralement dans la collecte et/ou l'étiquetage des données, afin de constituer les jeux de données d'entraînement. Un exemple de production participative (crowdsourcing) est le site Tomnod (désormais inactif), qui permet aux internautes de participer aux opérations de recherche à partir d'images satellites Maxar. En 2017, les internautes devaient classer les habitations comme inondées ou intactes après le passage de l'ouragan Harvey et ont permis la création d'un jeu de données d'entraînement de 12000 images.

A l'inverse, dans les travaux de cette thèse, la science citoyenne n'a pas contribué à la constitution des données d'entraînement (qui nécessite une certaine expertise en photo-interprétation), mais a contribué à l'adaptation d'un réseau de neurones convolutifs U-Net aux images Sentinel-2. Le travail collaboratif a impliqué des analystes de données (« data scientists ») de l'association Data For Good France<sup>14</sup>. Depuis 2015, l'association Data For Good France organise chaque année des saisons d'accélération de six semaines pour permettre à des bénévoles spécialisés notamment en machine learning, de proposer leurs compétences techniques à des chercheurs, ONG, ou associations pour des projets d'intérêt général. La collaboration entre les disciplines peut incontestablement bénéficier à la communauté de la cartographie de l'occupation du sol. Cette approche nous a permis d'obtenir un réseau de neurones U-Net respectant les exigences de la communauté des analystes de données, tout en montant en compétence sur les réseaux de neurones. Ainsi, l'apport de cette thèse est essentiellement l'articulation entre les connaissances issues des chapitres 2 et 3 avec celles des spécialistes des réseaux de neurones. Nous verrons dans la partie 4.3.2.2 que par la suite, deux autres modèles de segmentation sémantique ont été développés afin d'être comparés à ce premier modèle.

---

<sup>14</sup> [www.dataforgood.fr](http://www.dataforgood.fr)




Figure 52 : l'architecture U-Net pour la segmentation sémantique, modifiée à partir de Ronneberger et al. (2015).

U-Net, issu du réseau neuronal convolutif traditionnel, a été introduit par Olaf Ronneberger et al. en 2015 pour la détection d'objets dans des images biomédicales. U-Net effectue une classification sur chaque pixel, de sorte que l'entrée et la sortie ont la même taille. L'architecture du réseau U-Net est entièrement convolutive. U-Net se décompose en 3 sections : un chemin de contraction et un chemin d'expansion, qui lui donnent la forme d'un « U » (fig. 52).

Le chemin de contraction est la partie initiale du réseau et est un réseau de convolution. Il est appelé chemin de contraction parce qu'il réduit progressivement la taille des cartes de sorties, en apprenant une hiérarchie de caractéristiques, des plus détaillées (au début du réseau) aux plus grossières (vers la queue du réseau). Parce que le réseau ressemble un peu à une pyramide (il devient moins large à mesure que nous avançons vers l'aval), il se contracte et s'appelle un réseau contractuel.

Le chemin de contraction suit l'architecture habituel d'un réseau convolutif. D'abord, le chemin de contraction applique 2 couches de convolution qui réduisent les dimensions spatiales et crée une représentation abstraite de l'image d'entrée grâce aux fonctions qu'ils appliquent (flèches bleues dans la figure 52).

Chacune des convolutions est suivie d'une fonction linéaire rectifiée (ReLU) qui active ou non la sortie des convolutions. Le réseau finit par ce que l'on appelle une couche de « max-pooling » (flèches rouges dans la figure 52). La technique du max-pooling consiste à extraire la valeur maximum dans la fenêtre glissante de taille 2x2. Elle permet de réduire de manière importante la taille d'une image tout en gardant les informations les plus pertinentes du modèle. Cette séquence de 2 couches de convolution et d'une couche de max-pooling est appelé bloc ; le nombre de blocs convolutifs est configurable, mais est de 5 dans l'article de Ronneberger et al. (2015).

En résumé, grâce au chemin de contraction, une image d'entrée est sous-échantillonnée et plusieurs caractéristiques de l'image sont capturées et apprises par le modèle. Celles-ci peuvent maintenant être utilisées pour le suréchantillonnage des sorties du chemin de contraction.

A partir du chemin dit d'expansion, l'image va être agrandie à sa taille d'origine. Ce réseau de suréchantillonnage reconstruit l'image de sortie à une résolution spécifique. Le chemin d'expansion se compose du même nombre de blocs que dans le chemin de contraction, mais ces blocs sont des blocs de suréchantillonnage. Une concaténation est effectuée entre la sortie sur-échantillonnée de chacun des blocs avec la carte correspondante dans le chemin de contraction (flèches grises dans les figures 52 et 53). U-Net bénéficie de ces concaténations dans la mesure où elles transmettent des informations sur "ce que le réseau a vu" à un niveau particulier dans le chemin de contraction, vers le chemin d'expansion.




Figure 53 : Une concaténation (flèche en gris) en bas du U. Repris de Ronneberger et al. (2015).

Finalement, les blocs de suréchantillonnage génèrent une sortie de taille égale à l'image d'entrée dans les dimensions de largeur et de hauteur. Ce type d'architecture où le réseau est divisé en deux parties, un réseau de sous-échantillonnage puis un réseau de suréchantillonnage, est appelé réseau **Encodeur-Décodeur**.

Les réseaux de neurones convolutifs ont des structures internes, les filtres de convolution, qui préservent les relations spatiales apprises par le modèle. Les résultats de convolution sont les **cartes d'activation** (« feature maps »), et peuvent être extraits. La visualisation de ces cartes permet d'illustrer la représentation interne que le modèle U-Net a d'une image à un point donné du modèle (exemple pour un seul filtre de convolution en figure 54).




Figure 54 : exemple de la représentation interne du modèle U-Net avec les cartes d'activation extraites de chacun des blocs du réseau sur un filtre donné.

Le résultat de l'application des filtres dans le premier bloc est un grand nombre de versions de l'image de départ avec différentes caractéristiques mises en évidence. Par exemple, dans certains filtres les formes linéaires sont en surbrillance (1<sup>er</sup> filtre du bloc 1), d'autres se concentrent sur l'arrière-plan ou le premier plan. Les cartes d'activation proches de l'entrée du modèle (premiers blocs) détectent les détails fins, tandis que les cartes d'activation proches de la sortie du modèle (derniers blocs) capturent des

caractéristiques plus abstraites et générales. En somme, les différentes cartes permettent de prendre en compte plusieurs variables de l'organisation spatiale autour de chaque pixel.

Une optimisation du réseau a été testée avec l'appui de la science citoyenne. Pour éviter le sur-apprentissage et augmenter sa capacité de généralisation, une couche de « **dropout** » avec un taux de 0,2 a été introduit avant chaque bloc. Ce taux indique la probabilité qu'un neurone soit abandonné aléatoirement. Le « dropout » est une technique proposée par Srivastava et al. en 2014 pour limiter l'interdépendance entre les neurones d'une couche en ignorant aléatoirement des neurones pendant l'apprentissage, un peu à la manière de la sélection aléatoire des variables dans chaque arbre de l'algorithme Random Forest. Cela évite que le modèle sur-apprenne (« overfitting ») les données d'apprentissage. C'est un écueil courant dans les algorithmes d'apprentissage en profondeur dans lequel un modèle essaie de s'adapter entièrement aux données d'apprentissage et finit par mémoriser les agencements (patterns) de données. Ces modèles ne parviennent pas à généraliser et à bien fonctionner face à des données nouvelles, ce qui va à l'encontre de l'objectif du modèle.

#### 4.3.2.2. Comparaison avec d'autres réseaux de la littérature (SegNet, ResNet-Unet)

Le réseau U-Net est comparé à deux réseaux CNN de la littérature. Le premier, **SegNet**, est un modèle de segmentation sémantique proposé par Badrinarayanan et al. en 2017 (fig. 55). Cette architecture de segmentation de base entraînable se compose d'un réseau encodeur et d'un réseau décodeur comme U-Net. L'architecture du réseau encodeur présente 13 couches convolutives. Or dans Segnet, seuls les index de pooling (i.e. les emplacements des valeurs maximales pour chaque carte d'activation) sont transférés vers le chemin d'expansion à partir du chemin de compression, en utilisant moins de mémoire. Ceci diffère de U-Net, où des cartes d'activation entières sont transférées du chemin de compression à la fabrication du chemin d'expansion, en utilisant beaucoup plus de mémoire. Classiquement conçu et testé pour des images RGB et dans des tâches de segmentation d'images de route, SegNet est ici adapté aux images multispectrales Sentinel-2.

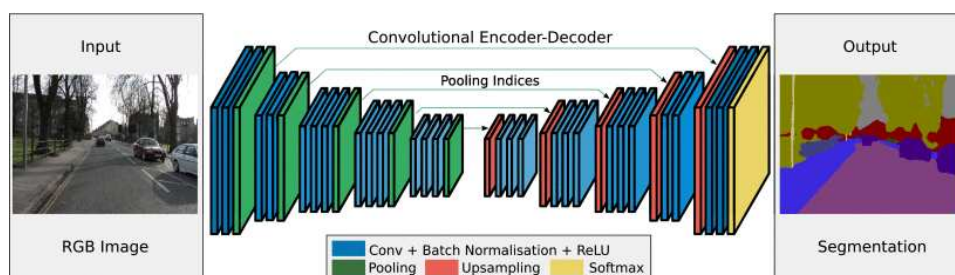


Figure 55 : architecture SegNet. Source : Badrinarayanan et al., 2017.

Le deuxième réseau implémenté est le **ResNet-Unet**. En 2020, Charng et al. font appel à cette architecture pour segmenter les taches rétinienne qui permettent le diagnostic de la maladie de Stargardt, l'une des formes les plus courantes de maladie rétinienne héréditaire. Il s'agit d'une

architecture qui suit la structure de U-Net avec un encodeur qui adopte le modèle résiduel ResNet (He et al., 2016), très répandu dans le domaine de la classification d'images. Contrairement aux réseaux de neurones convolutifs qui ont une architecture linéaire (un empilement de couches dont chaque sortie est uniquement connectée à la couche suivante), dans un réseau résiduel comme ResNet, des connexions de saut d'identité sont introduites afin que la sortie des couches précédentes soit reliée à la sortie de nouvelles couches pour les transmettre toutes les deux à la couche suivante (fig. 56). L'idée intuitive derrière cette approche est qu'elle garantit que la couche suivante apprend quelque chose de nouveau et différent de ce que ce que l'entrée a déjà encodé (puisqu'elle reçoit à la fois la sortie de la couche la sortie de la couche précédente et son entrée inchangée).




Figure 56 : un bloc résiduel de ResNet. Source : He et al., 2016.

Leur architecture permet la création de réseaux de neurones très profonds, a priori de meilleure précision que ceux ayant des architectures linéaires car ils ont la capacité d'extraire davantage d'informations et d'avoir ainsi une analyse plus avancée des images. Lors de l'utilisation d'une architecture U-Net seule, les classifications ont tendance à manquer de détails fins. Avec un ResNet dans la section d'encodeur de U-Net (la moitié gauche du U), les connexions par saut ajoutées entre les blocs du réseau peuvent pallier ce problème (fig. 57, source : Charng et al., 2020).

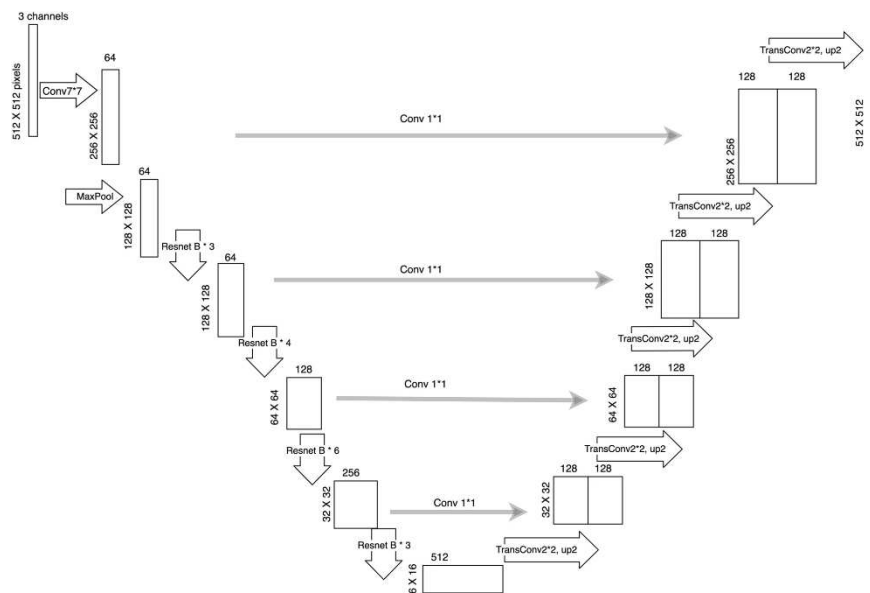


Figure 57 : Architecture de ResNet-UNet. La structure du ResNet-UNet utilise la structure U-Net, qui comprend des parties d'encodeur (sous-échantillonnage) et de décodeur (sur-échantillonnage). L'encodeur de sous-échantillonnage est remplacé par le modèle ResNet. Source : Charng et al., 2020.

#### 4.3.2.3. Paramétrage des modèles

Pendant l'entraînement du modèle, le paramètre qu'on appelle la **fonction de perte** doit être minimisé. Le choix de la fonction de perte doit correspondre au type de prédiction : classification binaire, multi-classe ou régression. Chaque probabilité de classe prédite est comparée à la sortie souhaitée de classe réelle 0 ou 1. Un score est calculé et pénalise la probabilité en fonction de sa distance par rapport à la valeur attendue réelle. La pénalité est de nature logarithmique donnant un grand score pour les grandes différences proches de 1 et un petit score pour les petites différences tendant vers 0.

L'une des fonctions de perte les plus couramment utilisées pour l'entraînement des réseaux de neurones en classification multi-classes est la perte d'entropie croisée catégorielle (« categorical cross entropy loss »).

$$L_{CE} = - \sum_{i=1}^n t_i \log(p_i) \text{ pour } n \text{ classes}$$

Où  $t_i$  est la valeur de référence et  $p_i$  est la probabilité donnée pour la  $i^{\text{ème}}$  classe.

Une seconde fonction de perte a été testée durant la thèse et a montré de meilleures performances (tests non montrés dans le manuscrit). La « dice loss » provient du coefficient de Sørensen-Dice et est une statistique développée dans les années 1940 pour évaluer la similitude entre deux échantillons. Il a été introduit dans la communauté du traitement d'image par Milletari et al. en 2016 pour la segmentation d'images médicales 3D. Cette fonction de perte est fréquemment citée dans le cas où les classes sont déséquilibrées, comme en Guinée forestière. Sa formule est donnée par :

$$D = \frac{2 \sum_i^N p_i g_i}{\sum_i^N p_i^2 + \sum_i^N g_i^2}$$

Dans laquelle  $p_i$  et  $g_i$  représentent des valeurs de pixel correspondantes de prédiction et de vérité terrain, respectivement.

Le nombre d'**époques** est un hyperparamètre qui décrit le nombre de passages complets du modèle à travers le jeu de données d'apprentissage. Une époque signifie que chaque donnée du jeu d'entraînement a eu la possibilité de mettre à jour les paramètres du modèle interne. On ne connaît pas le nombre d'époques nécessaires pour donner les meilleures performances sur un jeu de données. L'apprentissage des modèles est donc arrêté par « arrêt prématuré » (early stopping ) pour éviter le sur-entraînement des réseaux neuronaux. Il s'agit d'arrêter l'entraînement au moment où les performances sur le jeu de données commencent à se dégrader en surveillant une métrique de performance. Les paramètres d'entraînement sont présentés dans le tableau 10.



Tableau 10 : paramètres d'entraînement pour la comparaison des modèles.

| Parameter     | Value                             |
|---------------|-----------------------------------|
| Optimizer     | Adam (adaptive moment estimation) |
| Loss function | Dice loss                         |
| Batch Size    | 8                                 |
| Epochs        | 100                               |

#### 4.3.4. Tests pour le choix du meilleur modèle pour le projet ZAEG

##### 4.3.4.1. Taille du jeu d'entraînement

Le 1<sup>er</sup> test consiste à évaluer quel est l'impact de la taille du jeu d'entraînement sur les performances de classification, de façon similaire aux tests implémentés dans le chapitre 3, section 3.5. Il s'agit de voir si le nombre d'images d'entraînement améliore les précisions globales de classification (tableau 11). Seul le test avec le modèle U-Net sera présenté dans le manuscrit. L'intégralité des mesures de performances sera réalisée pour l'année 2021, non utilisée pour l'entraînement.

Tableau 11 : Tests sur la taille du jeu d'entraînement pour classer la forêt dégradée de 2021. a) Classification 2021 à partir d'une image, i.e. la donnée 2015 ou b) la donnée 2020 dans les données d'entraînement. c) Classification des données 2021 avec 2 images d'entraînement. d) Classification 2021 à partir des 4 données antérieures dans les données d'entraînement. e) Classification des données 2021 en utilisant 2 images de 2 massifs différents dans les données d'entraînement.

| Test | Images utilisées dans le jeu d'entraînement |      |      |      |        | Jeu de validation |       |        |
|------|---|------|------|------|--------|-------------------|-------|--------|
|      | Ziama                                       |      |      |      | Diécké | Ziama             | Nimba | Diecke |
|      | 2015  | 2017 | 2019 | 2020 | 2017   |                   |       |        |
| a    | X   |      |      |      |        | 2021              | 2021  | 2021   |
| b    |   |      |      | X    |        |                   |       |        |
| c    | X   |      |      |      | X      |                   |       |        |
| d    | X   | X    | X    | X    |        |                   |       |        |
| e    | X   |      |      |      | X      |                   |       |        |

##### 4.3.4.2. Choix du meilleur modèle et effet de la normalisation des données

Il s'agit de sélectionner le meilleur modèle de réseau de neurones convolutifs parmi U-Net, SegNet et ResNet-UNet pour la détection de forêts dégradées. Le meilleur modèle doit répondre à ces 2 critères :

- Être transférable d'une année à l'autre : i.e. produire la meilleure précision globale de classification du massif de Ziama en 2021 pour un même jeu d'entraînement,

- Présenter la meilleure capacité de généralisation face à une nouvelle zone géographique, comme le massif de Nimba.

Enfin, la performance des modèles a été comparée avec et sans étape de normalisation des données. Les données ont été normalisées en divisant chaque bande par la valeur maximale sur toute la série temporelle (tableau 12), afin que les pixels aient une valeur comprise entre 0 et 1. Les cartes de classification issues du modèle choisi sont ensuite soumises au protocole de validation externe d'IGN FI. Celle-ci permettra leur implémentation dans l'extension du projet ZAEG.

Tableau 12 : valeurs maximales sur la série temporelle utilisées pour la normalisation des données.

| <b>Sentinel-2 bands</b>                     | <b>Valeur maximale sur la série temporelle</b> |
|---|--|
| Bande 2 – bleu                              | 1,082  |
| Bande 3 - vert                              | 1,115  |
| Bande 4 – rouge                             | 1,131  |
| Bande 5 – végétation 'red edge' 1           | 0,562  |
| Bande 6 – végétation 'red edge' 2           | 0,680  |
| Bande 7 – végétation 'red edge' 3           | 0,773  |
| Bande 8 – proche infrarouge (PIR) "large"   | 1,395  |
| Bande 8A – proche infrarouge (PIR) "étroit" | 0,797  |
| Bande 11 - moyen infrarouge (MIR) 1         | 1,869  |
| Bande 12 - moyen infrarouge (MIR) 2         | 1,685  |
| CWC   | 0,161  |
| LAI   | 5,200  |
| MSI   | 13,828   |

#### 4.3.5. Validation externe des cartes produites par les experts IGN FI

La crédibilité et la fiabilité des informations que les cartes fournissent requièrent une validation indépendante. L'objectif de cette section est de décrire la validation externe des cartes instaurée chez IGN FI, utilisée dans tous les projets de cartographie d'OCS et répondant aux normes émises par la méthodologie VCS. Cette validation évalue dans notre cas la qualité des cartes de forêts dégradées produites par les méthodes d'apprentissage profond dans la thèse sur les 3 massifs protégés de Guinée. Une fois validées, ces cartes participeront à la mise à jour des cartes OCS de Guinée dans l'extension du projet ZAEG en 2022.

#### 4.3.5.1. Protocole de validation IGN FI

Le protocole consiste en un **plan d'échantillonnage aléatoire stratifié** pour la collecte des données de référence selon la méthode d'Olofsson et al. (2012). La stratification se construit sur les 3 classes de la classification 2021 forêt dense, forêt dégradée et non-forêt faite par DL dans ce chapitre (fig. 58). La stratification va générer un sous-ensemble impartial et représentatif de la population (Stehman, 2009) pour assurer la validité statistique, et cela est particulièrement vrai quand il y a un déséquilibre dans les surfaces des classes (Olofsson et al., 2012). Dans le massif de Ziama par exemple, les proportions surfaciques des classes forêt dense, forêt dégradée et autre sont respectivement de 33%, 13% et 54%. A l'intérieur de chacune de ces 3 strates, 100 sites mutuellement exclusifs sont aléatoirement ventilés dans chaque massif. Chaque site à valider est un carré de 1 hectare. Une contrainte de distance minimum de 100 mètres (la largeur d'une unité d'échantillonnage) entre les carrés est imposée (fig. 58).

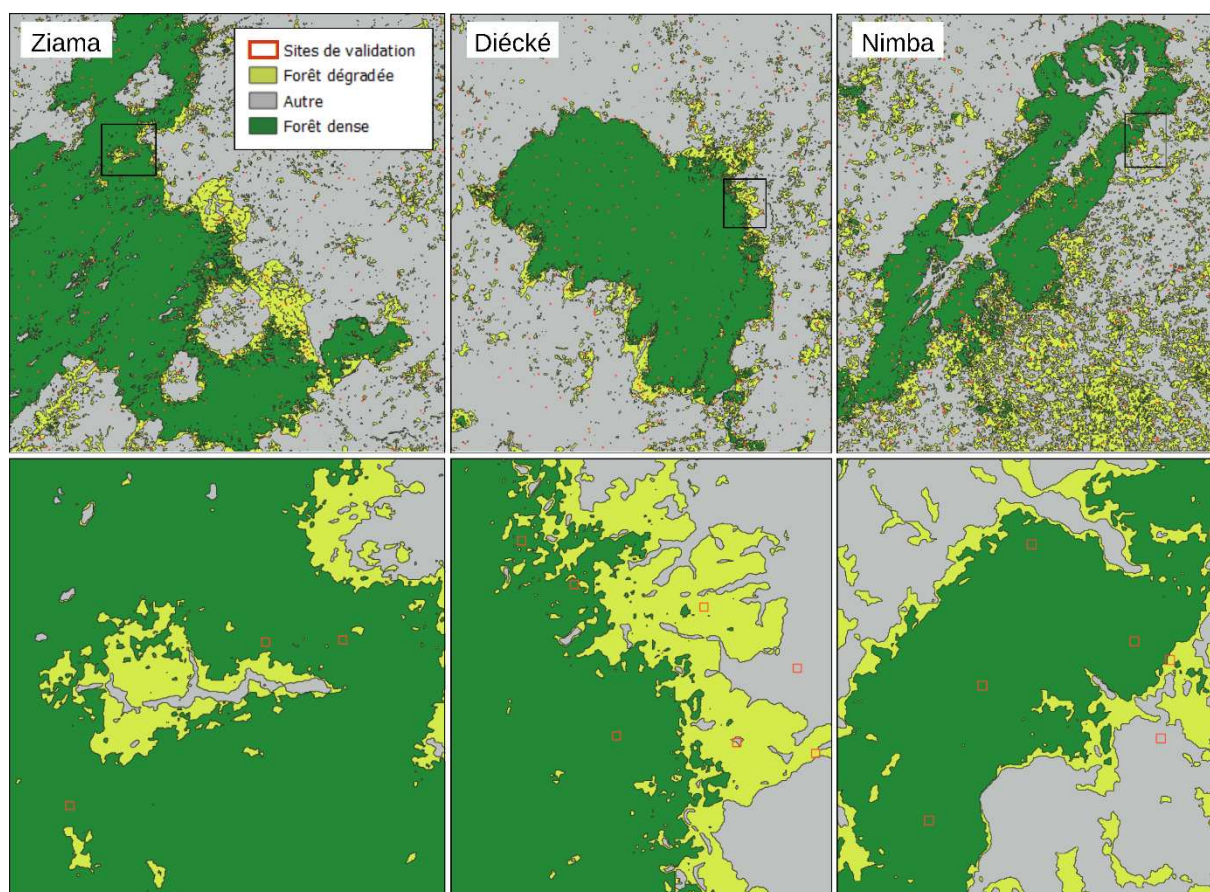


Figure 58 : Stratification et sites de validation de surface de 1 ha (carrés rouges) dans les massifs de Nimba, Diecke et Ziama en 2021. Dans la ligne du bas, des agrandissements sont donnés pour chaque massif.

En résumé, les 3 massifs de Ziama, Diecke et Nimba totalisent un échantillon global de 900 sites de validation répartis sur les 3 classes. Le processus de validation est divisé en 2 étapes successives d'interprétation visuelle de l'image Sentinel-2 2021 que le modèle a classé : la photo-interprétation « aveugle » ou « blind », un code de classe est attribué à chaque pixel de l'échantillon par un opérateur sans tenir compte du produit DL à valider. Le code de classe est attribué selon les règles définies dans

le projet ZAEG décrites dans la section 2.3 sur la base de la densité arborée. La photo-interprétation de la validation « plausibilité » est effectuée par des photo-interprètes indépendants (c'est-à-dire non impliqués dans l'interprétation en aveugle) pour toutes les unités d'échantillonnage où les résultats de l'interprétation en aveugle sont en désaccord avec les produits DL (comme décrit dans Szantoi et al., 2021). La liste des experts thématiques est donnée dans le tableau 13. La photo-interprétation de chaque unité d'échantillonnage est faite sur les images Sentinel-2 2021 que le modèle U-Net a classé, en combinaison avec des images très haute résolution en ligne disponibles, notamment Bing Maps et Google Earth.

Tableau 13 : 2 équipes de validation pour une 1ère puis une 2ème photo-interprétation des sites.

| 1ère validation (aveugle) | 2ème validation (plausibilité) |
|---------------------------|--------------------------------|
| Amadou Conté              | Gabriel Jaffrain               |
| Amara Kourouma            |                                |
| Yvon Aubriot              |                                |
| M'Ballou Sylla            |                                |

#### 4.3.5.2. Analyse de la précision thématique

La phase d'évaluation se conclut par l'analyse de la précision thématique, suivant l'approche d'Olofsson et al. (2013 et 2014). Une matrice d'erreur brute est d'abord générée par le biais d'une tabulation croisée entre le produit cartographique (lignes) et les données de référence (colonnes) pour tous les échantillons (tableau 14). Chaque élément de la matrice d'erreur brute sera désigné par  $n_{i,j}$  où  $i,j$  correspondent respectivement à la ligne (produit) et à la colonne (référence). Le nombre total de points dans le produit et dans la référence sont respectivement  $n_i$  et  $n_j$ . Pour calculer la proportion d'inclusion de chaque échantillon, on tient compte du poids de chaque classe dans le plan d'échantillonnage (proportion d'échantillons) et dans le produit (proportion de surfaces) (tableau 14). On génère ainsi une **matrice d'erreur normalisée** (tableau 15) dont chaque élément  $p_{ij}$  est calculé par la formule

$$p_{ij} = W_i \frac{n_{ij}}{n_i}$$

où  $W_i$  est le poids de la zone, calculé comme suit :

$$W_i = \frac{A_i}{A_{total}}$$

$A_i$  étant la surface de la classe  $i$  et  $A_{total}$  la surface totale.

Enfin, les erreurs ajustées aux surfaces pour chaque classe sont également être déduites de la matrice d'erreurs normalisée, en tenant compte des poids des surfaces des classes dans chaque massif (tableau 14) en utilisant la formule :  $\widehat{A}_{j+} = A_{total} \widehat{P}_{j+}$  où  $\widehat{P}_{j+}$  correspond à la somme des colonnes de la matrice d'erreurs normalisée et  $A_{total}$  est la surface totale cartographiée.

Tableau 14 : surfaces et poids des classes dans chaque massif pour la matrice d'erreur normalisé

| Massif | Classe         | Surface (ha) | Surface massif (ha) | Nombre d'unités | % de la surface du massif | Poids par unité |
|--------|----------------|--------------|---------------------|-----------------|---------------------------|-----------------|
| Ziama  | Forêt dense    | 84 493,95    | 255 352,99          | 100             | 33,0891%                  | 0,00331         |
|        | Forêt dégradée | 28 191,46    |                     | 100             | 11,0402%                  | 0,00110         |
|        | Autre          | 142 667,58   |                     | 100             | 55,8707%                  | 0,00559         |
| Diecke | Forêt dense    | 51 555,86    | 193 174,92          | 100             | 26,6887%                  | 0,00267         |
|        | Forêt dégradée | 16 695,17    |                     | 100             | 8,6425%                   | 0,00086         |
|        | Autre          | 124 923,89   |                     | 100             | 64,6688%                  | 0,00647         |
| Nimba  | Forêt dense    | 27 930,67    | 135 856,18          | 100             | 20,5590%                  | 0,00206         |
|        | Forêt dégradée | 30 137,53    |                     | 100             | 22,1834%                  | 0,00222         |
|        | Autre          | 77 787,98    |                     | 100             | 57,2576%                  | 0,00573         |

Tableau 15 : lecture d'une matrice de confusion normalisée.

|   |                        | En ligne sommes des poids liés aux surfaces des classes de la validation |   |   | Total en ligne                    | Précision utilisateur %       | Erreur de commission % |
|---|------------------------|--|---|---|-----------------------------------|-------------------------------|------------------------|
|   |                        | Classes  | 1 | 2 |                                   |                               |                        |
| En colonnes sommes des poids liés aux surfaces des classes de la classification | 1                      |  |   |   |                                   |                               |                        |
|   | 2                      |  |   |   |                                   |                               |                        |
|   | 3                      |  |   |   |                                   |                               |                        |
|   | Total en colonne       |  |   |   | Poids total des unités contrôlées | Précision moyenne utilisateur |                        |
|   | Précision producteur % |  |   |   | Précision moyenne producteur      | Précision globale             |                        |
|   | Erreur d'omission %    |  |   |   |                                   |                               |                        |

Pour que les cartes produites soient considérées comme valides, elles doivent répondre aux mêmes critères qualité des méthodologies VCS du chapitre 3 : 85 % de bonne classification globale et 80% de bonne classification intra-classe pour le produit DL.

## 4.4. Résultats

### 4.4.1. Impact de la taille du jeu d'entraînement

Les résultats du 1<sup>er</sup> test sur l'impact de la taille du jeu d'entraînement sont montrés dans le tableau 16. D'abord, ils montrent que les précisions globales augmentent lorsque le modèle U-Net s'entraîne sur plus de données, et qu'à partir d'un jeu d'entraînement de 4 images, le modèle CNN montre des précisions globales supérieures à 89% sur les massifs de Ziama et de Diécké (test f).

On note aussi l'instabilité des performances des modèles avec peu de données d'entraînement : les modèles qui ne se sont entraînés que sur 2 images présentent des précisions globales variant entre 75.0% et 88.4% sur le massif de Ziama (tests c, d et e) ; ces précisions sont parfois même inférieures à celles des tests qui n'ont impliqué qu'une image d'entraînement (tests a et b).

Tableau 16 : Précisions globales du réseau U-Net appliqué sur les 3 massifs en 2021. Le nombre d'époques lorsque le modèle est arrêté est aussi précisé.

| Test | Jeu d'entraînement |      |      |      |        |      | Modèle | Normalisation des données | Nombre d'époques | Ziama 2021-01-25 (OA) | Nimba 2021-01-25 (OA) | Diecke 2021-02-09 (OA) |
|------|--------------------|------|------|------|--------|------|--------|---------------------------|------------------|-----------------------|-----------------------|------------------------|
|      | Ziama              |      |      |      | Diécké |      |        |                           |                  |                       |                       |                        |
|      | 2015               | 2017 | 2019 | 2020 | 2017   | 2020 |        |                           |                  |                       |                       |                        |
| a    | x                  |      |      |      |        |      | U-Net  | Oui                       | 98               | 0.843                 | 0.758                 | 0.851                  |
| b    |                    |      |      | x    |        |      |        |                           | 11               | 0.802                 | 0.711                 | 0.852                  |
| c    | x                  |      |      | x    |        |      |        |                           | 24               | 0.870                 | 0.809                 | 0.933                  |
| d    | x                  |      |      |      | x      |      |        |                           | 42               | 0.750                 | 0.846                 | 0.846                  |
| e    | x                  |      |      |      |        | x    |        |                           | 100              | 0.884                 | 0.813                 | 0.935                  |
| f    | x                  | x    | x    | x    |        |      |        |                           | 47               | 0.893                 | 0.830                 | 0.935                  |

Par ailleurs, on remarque que dans le cas où l'image 2017 de Diécké fait partie du jeu d'apprentissage, les précisions globales sont plus faibles pour la classification de l'image 2021 de Diécké (test d, 84.6%), comparé aux autres tests qui n'ont connu que Ziama dans leur entraînement mais atteignent de meilleures précisions globales sur Diécké 2021 (test a, b et c ; allant de 85.1 à 93.3%).

A l'inverse, lorsque l'image 2020 de Diécké est utilisée dans l'entraînement, les précisions globales atteignent 93.5% sur Diécké 2021 (test e). Ces résultats peuvent être expliqués par l'écart des radiométries observé sur Diécké entre 2017 et 2020, lié aux plantations industrielles monocultures d'hévéas et leur abattage pour la production de caoutchouc. Le passage d'un couvert arboré dense et régulier vers un sol nu s'illustre sur la figure 59, où les plantations apparaissent en orange dans la composition colorée PIR/MIR/R sur Diécké. Les hévéacultures sont particulièrement présentes à Diécké et ne sont pas au même stade de croissance, ce qui implique de devoir fournir plusieurs représentations de plantations d'hévéas pour rendre le modèle plus robuste. Le fait que les jeux de données d'apprentissage sur Diécké 2020 présentent possiblement des représentations de plantations d'hévéas

plus proches de l'image à classer en 2021, peuvent expliquer que les modèles CNN soient plus performants.




Figure 59 : plantations d'hévéas (cercles noirs) sur le massif de Diécké entre 2017 et 2021.

Quant à la classification du mont Nimba en 2021, les précisions globales sont inférieures à celles observées sur Ziama et Diécké 2021, puisque les modèles CNN n'ont pas été entraînés sur la zone. Ces précisions globales tendent à augmenter lorsque le nombre d'images d'entraînement croît. C'est pourquoi, par la suite, la totalité du jeu de données photo-interprété (de 10 images à Ziama et 4 images à Diécké) est utilisé dans l'apprentissage des modèles.

#### 4.4.2. Comparaison des modèles et effet de la normalisation des données

Les 3 modèles U-Net, SegNet et ResNet-UNet sont appliqués aux images Sentinel-2 acquises sur Ziama, Diecke et Nimba en 2021 pour évaluer leur qualité. La classification des pixels de ce jeu de données de validation est comparée aux valeurs fournies par les cartes photo-interprétées 2021. Les tableaux 17 et 18 résument les résultats. Ils montrent la précision globale pour les 3 classes et pour chaque modèle, dans le cas où les données ne sont pas normalisées (tableau 17) et normalisées (tableau 18).

Tableau 17 : Statistiques des 3 modèles CNN sur les 3 massifs en 2021, sans normalisation des données.

| Jeu d'entraînement        | Nom         | Normalisation | Nombre d'époques | Ziama 2021-01-25 (OA) | Nimba 2021-01-25 (OA) | Diecke 2021-02-09 (OA) | Moyenne OA |
|---------------------------|-------------|---------------|------------------|-----------------------|-----------------------|------------------------|------------|
| Ziama + Diecke (14 dates) | U-Net       | Non           | 18               | 0.8155                | 0.7580                | 0.8968                 | 0.8234     |
|                           | SegNet      |               | 48               | 0.8384                | 0.7410                | 0.8176                 | 0.7990     |
|                           | ResNet-UNet |               | 33               | 0.7975                | 0.7109                | 0.9069                 | 0.8051     |

Tableau 18 : Statistiques des 3 modèles CNN sur les 3 massifs en 2021, avec normalisation des données.

| Jeu d'entraînement        | Nom         | Normalisation | Nombre d'époques | Ziama 2021-01-25 (OA) | Nimba 2021-01-25 (OA) | Diecke 2021-02-09 (OA) | Moyenne OA |
|---------------------------|-------------|---------------|------------------|-----------------------|-----------------------|------------------------|------------|
| Ziama + Diecke (14 dates) | U-Net       | Oui           | 82               | 0.9441                | 0.9033                | 0.9561                 | 0.9345     |
|                           | SegNet      |               | 91               | 0.8984                | 0.8327                | 0.9330                 | 0.8880     |
|                           | ResNet-UNet |               | 50               | 0.9380                | 0.9010                | 0.9540                 | 0.9310     |

Avec les données non normalisées, aucun modèle ne montre de précision globale au dessus de 85% à la fois sur les 3 massifs. A l'inverse, tous les réseaux CNN parviennent à atteindre des précisions dépassant 85%. Les modèles U-Net et ResNet-UNet montrent même des précisions globales supérieures à 90% sur les 3 massifs avec les données normalisées. Cela suggère que la normalisation, en ajustant des valeurs mesurées à différentes échelles à une échelle commune, semble réduire la complexité des modèles d'apprentissage profond. Les cartes de classification produites par le modèle U-Net sont montrées sur les massifs de Diécké et de Nimba (respectivement en haut et en bas, en figure 60) avec et sans normalisation des données. Les cartes de classification montrent à quel point les modèles CNN sont plus robustes quand la normalisation des images satellites est effectuée.




Figure 60 : avant et sans normalisation sur le massif de Diécké et le mont Nimba.



Enfin, le choix du meilleur modèle se porte sur le réseau U-Net. Dans l'ensemble, il atteint la meilleure précision avec 93,45% que les autres architectures (respectivement 88,80% pour SegNet et 93,10% pour ResNet-Unet). Ensuite, il atteint les meilleures précisions globales sur tous les massifs. U-Net classe avec justesse 94,41% des pixels sur Ziama et 95,61% sur Diécké sur l'année 2021. Il parvient à atteindre 90,33% de pixels correctement classés sur le mont Nimba, pour lequel il n'a pas été entraîné.

Les statistiques complètes pour les modèles U-Net sont données dans le tableau 19 pour les 3 massifs. Ces statistiques sont calculées par rapport à l'image photo-interprétée de référence. On constate que la détection de la classe des forêts dégradées fonctionne relativement bien pour les 3 modèles, mais la classe « forêt dégradée » reste la classe la plus difficile à classer. Sur le mont Nimba, on note que le modèle montre des confusions entre la classe « forêt dégradée » et la « forêt dense ». Les précisions producteur et utilisateur de la classe « forêt dense » sont légèrement plus mauvaises sur Nimba (respectivement 88,4% et 93,6%) que sur les deux autres massifs (toutes supérieures à 95%).

Surtout, les valeurs de précision producteur et précision utilisateur de la classe « forêt dégradée » varient globalement entre 73% et 81,3% sur les 3 massifs, ce qui représente une amélioration comparée aux mêmes métriques de la méthode Random Forest contextuelle développée au chapitre 3.

Tableau 19 : durée de traitement et statistiques du réseau U-Net des classifications sur les 3 massifs sur l'année 2021. PA = précision producteur ; UA = précision utilisateur.

| CNN   | Massif (2021) | Durée de classification | OA    | PA 'forêt dense' | UA 'forêt dense' | PA 'forêt dégradée' | UA 'forêt dégradée' | PA 'Autre' | UA 'Autre' |
|-------|---------------|-------------------------|-------|------------------|------------------|---------------------|---------------------|------------|------------|
| U-Net | Ziama         | 2 ' 25 ''               | 0.944 | 0.950            | 0.963            | 0.792               | 0.732               | 0.97       | 0.978      |
|       | Nimba         | 2 ' 08 ''               | 0.903 | 0.884            | 0.936            | 0.813               | 0.731               | 0.935      | 0.954      |
|       | Diécké        | 1 ' 50 ''               | 0.956 | 0.951            | 0.987            | 0.782               | 0.734               | 0.982      | 0.975      |

#### 4.4.3. Validation externe

La carte de classification par le modèle U-Net a donc été soumise à une validation indépendante par IGN FI. Après inspection visuelle de toutes les unités d'échantillonnage, les matrices d'erreur brutes sont construites pour les cartes de forêts dégradées de 2021 (annexe A.3). Les précisions globales 'brutes' pour chacun des massifs sont respectivement de 91,3%, 86,0% et 89,0% pour Ziama, Diécké et Nimba d'après la validation externe. Pour l'ensemble des massifs, la précision globale brute est de 88,8%.

Enfin, les matrices d'erreur normalisées par rapport aux poids des surfaces de chaque classe sont données dans les tableaux 20 et 21. On obtient des précisions globales ajustées de 96,9%, 93,9% et 91,5% respectivement pour Ziama, Diécké et Nimba. Pour l'ensemble des massifs, la précision globale ajustée est de 94,1%. Ensuite, la classe des forêts dégradées présente des précisions utilisateur et producteur de 72,3% et de 83,9% respectivement.

Il apparaît donc que la méthode DL a considéré davantage de surface en forêts dégradées comparé à la validation. Cela est cohérent dans la mesure où elle fait appel à d'autres paramètres biophysiques qui ne sont pas intégrés dans la photo-interprétation. Outre la densité arborée, elle intègre des mesures de surface foliaire, de contenu hydrique de la canopée et de stress hydrique que les photo-interprètes ne considèrent pas et qui n'apparaissent pas via une interprétation visuelle des images brutes. Ceci peut expliquer que le réseau CNN produit des cartes qui vont montrer plus de forêts dégradées que ce que la validation n'en détecte.

En résumé, U-Net surpasse l'algorithme Random Forest en termes de statistiques d'évaluation (précision globale OA, précisions utilisateur/producteur) et de rendu cartographique. Les réseaux de neurones convolutifs permettent ainsi de détecter les schémas de dégradation forestière en Guinée, en présentant l'avantage de ne pas avoir à photo-interpréter l'image nouvellement acquise pour l'entraînement des modèles. Le modèle U-Net est transférable à la fois d'une année à l'autre, et d'un massif à l'autre.

Tableau 20 : : matrices d'erreur normalisées pour chaque massif. UA : précision utilisateur, PA : précision producteur, EC : erreur de commission, EO : erreur d'omission, OA : précision globale.

| Ziama                      |              |               |              |       |               |              | Ziama                      |              |               |              |       |               |              |
|----------------------------|--------------|---------------|--------------|-------|---------------|--------------|----------------------------|--------------|---------------|--------------|-------|---------------|--------------|
| Interprétation à l'aveugle |              |               |              |       |               |              | Analyse de la plausibilité |              |               |              |       |               |              |
| Classes                    | 1            | 2             | 3            | Total | UA            | EC           | Classes                    | 1            | 2             | 3            | Total | UA            | EC           |
| 1                          | 32,7         | 0,0           | 0,0          | 32,7  | <b>100,0%</b> | <b>0%</b>    | 1                          | 32,7         | 0,0           | 0,0          | 32,7  | <b>100,0%</b> | <b>0,0%</b>  |
| 2                          | 2,7          | 5,9           | 3,2          | 11,8  | <b>50,0%</b>  | <b>50%</b>   | 2                          | 1,4          | 8,7           | 1,6          | 11,8  | <b>74,0%</b>  | <b>26,0%</b> |
| 3                          | 0,0          | 0,0           | 55,5         | 55,5  | <b>100,0%</b> | <b>0%</b>    | 3                          | 0,0          | 0,0           | 55,5         | 55,5  | <b>100,0%</b> | <b>0,0%</b>  |
| Total                      | 35,4         | 5,9           | 58,7         | 100,0 |               |              | Total                      | 34,1         | 8,7           | 57,2         | 100,0 |               |              |
| <b>PA</b>                  | <b>92,4%</b> | <b>100,0%</b> | <b>94,6%</b> |       |               |              | <b>PA</b>                  | <b>95,9%</b> | <b>100,0%</b> | <b>97,1%</b> |       |               |              |
| <b>EO</b>                  | <b>7,6%</b>  | <b>0,0%</b>   | <b>5,4%</b>  |       | <b>OA</b>     | <b>94,1%</b> | <b>EO</b>                  | <b>4,1%</b>  | <b>0,0%</b>   | <b>2,9%</b>  |       | <b>OA</b>     | <b>96,9%</b> |

| Diecke                     |              |              |              |       |              |              | Diecke                     |              |              |              |       |              |              |
|----------------------------|--------------|--------------|--------------|-------|--------------|--------------|----------------------------|--------------|--------------|--------------|-------|--------------|--------------|
| Interprétation à l'aveugle |              |              |              |       |              |              | Analyse de la plausibilité |              |              |              |       |              |              |
| Classes                    | 1            | 2            | 3            | Total | UA           | EC           | Classes                    | 1            | 2            | 3            | Total | UA           | EC           |
| 1                          | 26,4         | 0,3          | 0,0          | 26,7  | <b>99,0%</b> | <b>1%</b>    | 1                          | 26,4         | 0,3          | 0,0          | 26,7  | <b>99,0%</b> | <b>1,0%</b>  |
| 2                          | 3,1          | 2,2          | 3,3          | 8,6   | <b>26,0%</b> | <b>74%</b>   | 2                          | 2,1          | 5,4          | 1,1          | 8,6   | <b>63,0%</b> | <b>37,0%</b> |
| 3                          | 0,0          | 3,2          | 61,4         | 64,7  | <b>95,0%</b> | <b>5%</b>    | 3                          | 0,0          | 2,6          | 62,1         | 64,7  | <b>96,0%</b> | <b>4,0%</b>  |
| Total                      | 29,5         | 5,7          | 64,7         | 100,0 |              |              | Total                      | 28,5         | 8,3          | 63,2         | 100,0 |              |              |
| <b>PA</b>                  | <b>89,5%</b> | <b>39,1%</b> | <b>94,9%</b> |       |              |              | <b>PA</b>                  | <b>92,7%</b> | <b>65,6%</b> | <b>98,2%</b> |       |              |              |
| <b>EO</b>                  | <b>10,5%</b> | <b>60,9%</b> | <b>5,1%</b>  |       | <b>OA</b>    | <b>90,1%</b> | <b>EO</b>                  | <b>7,3%</b>  | <b>34,4%</b> | <b>1,8%</b>  |       | <b>OA</b>    | <b>93,9%</b> |

| Nimba                      |              |              |              |       |              |              | Nimba                      |              |              |              |       |              |              |
|----------------------------|--------------|--------------|--------------|-------|--------------|--------------|----------------------------|--------------|--------------|--------------|-------|--------------|--------------|
| Interprétation à l'aveugle |              |              |              |       |              |              | Analyse de la plausibilité |              |              |              |       |              |              |
| Classes                    | 1            | 2            | 3            | Total | UA           | EC           | Classes                    | 1            | 2            | 3            | Total | UA           | EC           |
| 1                          | 14,1         | 0,4          | 0,1          | 14,7  | <b>96,0%</b> | <b>4%</b>    | 1                          | 14,1         | 0,4          | 0,1          | 14,7  | <b>96,0%</b> | <b>4,0%</b>  |
| 2                          | 3,5          | 11,7         | 6,5          | 21,7  | <b>54,0%</b> | <b>46%</b>   | 2                          | 0,9          | 16,2         | 4,5          | 21,7  | <b>75,0%</b> | <b>25,0%</b> |
| 3                          | 0,0          | 8,9          | 54,7         | 63,6  | <b>86,0%</b> | <b>14%</b>   | 3                          | 0,0          | 2,5          | 61,1         | 63,6  | <b>96,0%</b> | <b>4,0%</b>  |
| Total                      | 17,6         | 21,0         | 61,4         | 100,0 |              |              | Total                      | 15,0         | 19,2         | 65,8         | 100,0 |              |              |
| <b>PA</b>                  | <b>80,3%</b> | <b>55,6%</b> | <b>89,2%</b> |       |              |              | <b>PA</b>                  | <b>94,2%</b> | <b>84,5%</b> | <b>92,9%</b> |       |              |              |
| <b>EO</b>                  | <b>19,7%</b> | <b>44,4%</b> | <b>10,8%</b> |       | <b>OA</b>    | <b>80,5%</b> | <b>EO</b>                  | <b>5,8%</b>  | <b>15,5%</b> | <b>7,1%</b>  |       | <b>OA</b>    | <b>91,5%</b> |

Tableau 21 : matrice d'erreur normalisée globale.

| Global                     |              |              |              |       |              |              | Global                     |              |              |              |       |              |              |
|----------------------------|--------------|--------------|--------------|-------|--------------|--------------|----------------------------|--------------|--------------|--------------|-------|--------------|--------------|
| Interprétation à l'aveugle |              |              |              |       |              |              | Analyse de la plausibilité |              |              |              |       |              |              |
| Classes                    | 1            | 2            | 3            | Total | UA           | EC           | Classes                    | 1            | 2            | 3            | Total | UA           | EC           |
| 1                          | 73,3         | 0,7          | 0,1          | 74,1  | <b>98,8%</b> | <b>1,2%</b>  | 1                          | 73,3         | 0,7          | 0,1          | 74,1  | <b>98,8%</b> | <b>1,2%</b>  |
| 2                          | 9,3          | 19,8         | 13,0         | 42,1  | <b>47,1%</b> | <b>52,9%</b> | 2                          | 4,4          | 30,4         | 7,3          | 42,1  | <b>72,3%</b> | <b>27,7%</b> |
| 3                          | 0,0          | 12,1         | 171,7        | 183,8 | <b>93,4%</b> | <b>6,6%</b>  | 3                          | 0,0          | 5,1          | 178,7        | 183,8 | <b>97,2%</b> | <b>2,8%</b>  |
| Total                      | 82,5         | 32,7         | 184,8        | 300,0 |              |              | Total                      | 77,6         | 36,2         | 186,2        | 300,0 |              |              |
| <b>PA</b>                  | <b>88,8%</b> | <b>60,7%</b> | <b>92,9%</b> |       |              |              | <b>PA</b>                  | <b>94,4%</b> | <b>83,9%</b> | <b>96,0%</b> |       |              |              |
| <b>EO</b>                  | <b>11,2%</b> | <b>39,3%</b> | <b>7,1%</b>  |       | <b>OA</b>    | <b>88,3%</b> | <b>EO</b>                  | <b>5,6%</b>  | <b>16,1%</b> | <b>4,0%</b>  |       | <b>OA</b>    | <b>94,1%</b> |

## 4.5. Conclusion sur la détection des forêts dégradées avec le deep learning

Dans cette étude, nous avons identifié le manque de données labellisées comme obstacle majeur pour l'entraînement de modèles de réseaux de neurones convolutifs. Pour améliorer la précision des modèles CNN, nous avons élargi les données d'entraînement en photo-interprétant 14 images sources disponibles entre 2015 et 2020 totalisant 2,7 millions d'hectares sur le massif de Ziama et le massif de Diecke.

Nous avons comparé trois modèles CNN différents et évalué leur utilité pour la classification des forêts dégradées. Nous pensons qu'une telle comparaison fournit des informations utiles aux chercheurs et aux autres parties prenantes impliquées dans le suivi des forêts tropicales pour le choix d'un modèle adapté. Nous avons ensuite entraîné les 3 modèles et les avons appliqués aux données 2021 pour évaluer leur qualité et leur capacité de généralisation.

Le résultat de l'étude est la création d'un système de détection automatique de forêts dégradées en Guinée. Les premiers résultats sont prometteurs tant sur le plan qualitatif que quantitatif par rapport aux produits automatisés. Un total de 900 unités d'échantillonnage de 100 × 100 m ont été visuellement interprétés par une équipe de photo-interprètes indépendamment de la production de la carte pour produire un ensemble de données de référence représentant 900 ha. Les résultats de cette validation externe est une précision globale de la carte supérieure à 94 %. La segmentation sémantique et en particulier, l'architecture U-Net, est capable de classer l'image, tout en tenant compte des informations contextuelles. Le modèle permet de détecter automatiquement les schémas de dégradation forestière dans les images satellites et fournit des résultats en moins de 3 minutes pour une zone de 255 000 km<sup>2</sup>.

L'apprentissage profond offre un important potentiel dans les disciplines où des outils spécialisés et automatisés n'existent pas encore. L'intégration de la science citoyenne et des réseaux neuronaux convolutifs dans les travaux de thèse peut montrer des résultats synergiques pour améliorer le suivi de la santé des ressources forestières en fournissant une construction rapide et précise de modèles. Le travail collaboratif avec la science citoyenne permet de conserver l'expertise sur la donnée satellite et sur l'application (la forêt), en capitalisant sur les développements spécialisés et récents en traitement d'images.



## Chapitre 5

### Conclusion et perspectives

La dégradation des forêts, concerne des territoires beaucoup plus étendus que ceux impactés par la déforestation : environ 6,5 millions de kilomètres carrés de forêt sont à haut risque de dégradation au cours des 10 prochaines années selon le World Wide Fund for Nature (WWF).

Dans le projet ZAEG, les opérateurs ont interprété visuellement les forêts dégradées puis numérisé les polygones de façon manuelle à partir de l'imagerie SPOT-6 monodate ce qui peut devenir chronophage lorsque ces surfaces de dégradation deviennent conséquentes et morcelées dans les massifs forestiers. La méthode de photo-interprétation utilisée dans ce projet a aussi montré des imperfections constatées sur le terrain en avril 2019. L'apport de Sentinel-2 et de la dimension temporelle pour la visualisation et la cartographie des forêts dégradées a été étudié dans ce travail de thèse.

#### 5.1. Synthèse des résultats sur la détection des forêts dégradées

Les données Sentinel-2 disposent de bandes spectrales dans le moyen-infrarouge (MIR), qui s'est révélé très adapté à la détection des forêts dégradées dans notre étude en raison de sa sensibilité au stress hydrique de la végétation. La composition colorée PIR/MIR/rouge sur Sentinel-2 améliore la lisibilité des images. Une méthode de photo-interprétation des forêts dégradées a été mise au point en se basant sur des critères de texture, de couleur et de contexte. Nous avons étudié l'incidence de la période d'acquisition sur la séparabilité des forêts denses et dégradées, et comparé notre méthode de photo-interprétation à celle utilisée sur SPOT-6 avec les bandes PIR, rouge et vert dans le projet ZAEG. Il apparaît que la composition colorée PIR/MIR/rouge des images Sentinel-2 donne de meilleurs résultats que celle utilisée dans le projet ZAEG sur SPOT-6 (PIR/rouge/vert) pour discerner les différences de texture et de couleur, particulièrement en saison sèche, entre décembre et mars. Par ailleurs, la dimension temporelle permet de lever de nombreuses confusions entre les radiométries des forêts dégradées et d'autres occupations du sol telles que les systèmes agroforestiers. La visualisation monodate des radiométries brutes PIR, MIR et rouge ne permet pas toujours de visualiser les degrés de dégradation forestière plus légers, que l'on constate sur le terrain. La validation des classes forestières est le plus souvent réalisée à travers l'examen chronologique des images Sentinel-2.

Lors des observations de la campagne de terrain et avec l'aide des gardes forestiers guinéens, les forêts dégradées ont pu être caractérisées par un changement structurel marqué, lié à la présence de lianes invasives et des traces au sol de l'exploitation des ressources. Ceci se décèle par la suite dans les radiométries de Sentinel-2, en raison de la sensibilité de la bande MIR au contenu en eau du couvert arboré.

Plusieurs méthodes de détection de forêts dégradées à partir d'images optiques ont été testées. Ces méthodes sont issues de la littérature. Les méthodes supervisées, c'est-à-dire aidées de données *a priori*

ont été principalement utilisées, comme la classification supervisée Random Forest. La classification multi-temporelle à partir des fractions subpixellaires de l'analyse SMA a donné de bons résultats mais n'est pas envisageable en termes d'opérationnalisation et de transférabilité dans un projet de cartographie d'occupation du sol, car les valeurs de pixels de référence requises varient d'une zone à l'autre et la sélection de pixels purs de 10 m sur 10 m est particulièrement délicate, ce qui rend la méthode SMA trop instable.

Au-delà de l'interprétation visuelle des compositions colorées conventionnelles des images SPOT, l'inclusion d'indices spectraux basés sur le MIR facilite la détection automatique des forêts dégradées à travers les méthodes décrites aux chapitres 3 et 4. La classification supervisée d'indices multi-temporels liés à l'humidité du feuillage de la canopée (MSI, CWC) et liés à la surface foliaire (LAI) donne également de bons résultats. Le principe de sélection de ROI polygonaux pallie le problème de pixels homogènes de l'analyse SMA. L'analyse des séries temporelles des indices MSI, CWC et LAI montre une très bonne séparabilité des classes arborées : forêts denses, forêts dégradées, systèmes agroforestiers et plantations. Les forêts dégradées montrent un gradient de stress hydrique dans le temps à travers les comportements observés de MSI, LAI et CWC. Particulièrement, les forêts dégradées identifiées par le projet ZAEG sont celles qui montrent un stress hydrique très élevé (et une surface foliaire très faible) ; leur degré de dégradation est prononcé et ceci explique leur détection facilitée dans le projet ZAEG.

En intégrant à la fois les indices liés à l'humidité du feuillage et sa surface foliaire (MSI, CWC, LAI), nous avons montré que la détection de forêts dégradées à partir d'images Sentinel-2 était possible avec le voisinage spatial. La prise en compte du voisinage surpasse les méthodes précédentes en limitant la mauvaise classification des pixels isolés et en améliorant les statistiques d'évaluation des modèles. La classification Random Forest prend compte des attributs des pixels voisins et semble prometteuse : la photo-interprétation de 1,6 % d'une nouvelle image du massif de Ziama permet au modèle d'inférer sur le reste de l'image avec des niveaux de performance satisfaisants. Cependant la méthodologie est limitée par la mémoire vive de l'ordinateur utilisé, rapidement saturée par la quantité de donnée d'entraînement. Dans notre étude, le modèle hybride Random Forest n'a pu s'entraîner que sur l'équivalent de 2 images du massif de Ziama (environ 4200 km<sup>2</sup>). La taille du jeu d'entraînement restreint sa capacité de généralisation.

Il apparaît que la méthode à la fois la plus robuste et opérationnelle est la classification par apprentissage profond ou deep learning. Bien que relativement longue en temps d'apprentissage puisqu'elle nécessite une grande quantité de données d'entraînement, elle permet d'inférer sur de nouvelles données avec de bons scores de précision. Cette méthode présente l'intérêt de pouvoir être généralisable car le modèle U-Net aura été entraîné sur divers massifs et à diverses dates. Le principal avantage réside dans la quantité nulle de photo-interprétation requise pour inférer une nouvelle image. On s'attachera à entraîner suffisamment le modèle au préalable, avant de le transmettre aux utilisateurs.

La procédure de validation indépendante par IGN FI (par photo-interprétation) a montré que la méthode deep learning a considéré plus de forêts dégradées comparé à la validation, en raison des paramètres

biophysiques additionnels qui ne sont pas accessibles par l'interprétation visuelle des images. Notamment les mesures de surface foliaire, de contenu hydrique de la canopée et de stress hydrique que les photo-interprètes ne peuvent pas visualiser. Au total, la validation était en désaccord sur 101 points avec le produit cartographique deep learning sur les 900 unités d'échantillonnage. Parmi ces 101 divergences, 88 points concernaient des désaccords sur la classe de forêt dégradée. Une inspection sur le terrain permettrait de clarifier ces points litigieux.

Les produits cartographiques issus du deep learning permettent de visualiser la distribution spatiale des forêts dégradées dans les massifs guinéens, mais la progression de la dégradation forestière d'une année à l'autre n'est pas encore pleinement interprétable pixel à pixel parce que la détection des forêts dégradées repose essentiellement sur la sensibilité du capteur au stress hydrique du couvert.

En outre, un jeu de données labellisé a ainsi été construit pour cette méthode, comprenant 14 cartes photo-interprétées sur Ziama et Diécké de 2015 à 2020 à partir de l'imagerie Sentinel-2 et de la méthode de photo-interprétation établie au chapitre 3. Ce jeu de données, enrichi des indices MSI, CWC et LAI, couvre plus de 27 000 km<sup>2</sup> et représente une base pour de futures études dans l'usage de l'apprentissage profond.

Enfin les travaux de thèse ont montré également que le développement de méthodes de détection des forêts dégradées basées sur des outils libres est possible, favorisant ainsi leur diffusion auprès des utilisateurs. Une partie des travaux présentés dans ce manuscrit a fait l'objet d'un transfert de compétences au responsable technique du projet ZAEG, validant ainsi l'interopérabilité et la reproductibilité des méthodes proposées.

Le tableau 22 et la figure 61 synthétisent les résultats des travaux de thèse dans le massif de Ziama. Les méthodologies développées pendant la thèse sont appliquées sur l'image Sentinel-2 2021. Elles sont toutes évaluées au regard du jeu de validation qui a été utilisé pour la validation externe au chapitre 4, c'est-à-dire les 300 unités photo-interprétées en aveugle puis corrigées par la plausibilité. On y compare :

- i) la carte de Ziama 2021, construite par la méthode de photo-interprétation décrite dans le chapitre 2,
- ii) les résultats de classification des méthodes Random Forest contextuelle et non-contextuelle du chapitre 3 appliquées à l'image Sentinel-2 2021 et,
- iii) les résultats issus des 3 réseaux neuronaux convolutifs implémentés dans le chapitre 4 sur la même image Sentinel-2, respectivement U-Net, SegNet et Resnet-U-net.

Pour tous les produits cartographiques, les poids surfaciques des classes et les précisions globales de la validation externe ont été calculées. Le meilleur modèle, U-Net, est surligné. Le détail des matrices brutes et normalisées de la validation externe sur toutes les cartographies est dans le tableau 22.



Tableau 22 : matrices d'erreur brutes et normalisées pour la carte photo-interprétée **Ziama** 2021, pour les 3 modèles CNN (U-Net, SegNet, Resnet-UNet) et pour les 2 modèles Random Forest avec et sans contexte régional dans l'algorithme. UA : précision utilisateur, PA : précision producteur, EC : erreur de commission, EO : erreur d'omission, OA : précision globale. Les indicateurs sont calculés par comparaison aux 300 points de la validation externe décrite au chapitre 4.

### Chapitre 2

| PI 2021   | Matrices brutes |              |              |       |              |              | PI 2021   | Matrices normalisées |              |              |       |              |              |
|-----------|-----------------|--------------|--------------|-------|--------------|--------------|-----------|----------------------|--------------|--------------|-------|--------------|--------------|
| Classes   | 1               | 2            | 3            | Total | UA           | EC           | Classes   | 1                    | 2            | 3            | Total | UA           | EC           |
| 1         | 100             | 2            | 1            | 103   | <b>97,1%</b> | <b>3%</b>    | 1         | 32,2                 | 0,6          | 0,3          | 33,2  | <b>97,1%</b> | <b>2,9%</b>  |
| 2         | 12              | 68           | 11           | 91    | <b>74,7%</b> | <b>25%</b>   | 2         | 1,4                  | 8,1          | 1,3          | 10,9  | <b>74,7%</b> | <b>25,3%</b> |
| 3         |                 | 4            | 102          | 106   | <b>96,2%</b> | <b>4%</b>    | 3         | 0,0                  | 2,1          | 53,9         | 56,0  | <b>96,2%</b> | <b>3,8%</b>  |
| Total     | 112             | 74           | 114          | 300   |              |              | Total     | 33,6                 | 10,9         | 55,5         | 100,0 |              |              |
| <b>PA</b> | <b>89,3%</b>    | <b>91,9%</b> | <b>89,5%</b> |       |              |              | <b>PA</b> | <b>95,7%</b>         | <b>74,7%</b> | <b>97,1%</b> |       |              |              |
| <b>EO</b> | <b>10,7%</b>    | <b>8,1%</b>  | <b>10,5%</b> |       | <b>OA</b>    | <b>90,0%</b> | <b>EO</b> | <b>4,3%</b>          | <b>25,3%</b> | <b>2,9%</b>  |       | <b>OA</b>    | <b>94,2%</b> |

### Chapitre 3

| RF sans contexte | Matrices brutes |              |              |       |              |              | RF sans contexte | Matrices normalisées |              |              |       |              |              |
|------------------|-----------------|--------------|--------------|-------|--------------|--------------|------------------|----------------------|--------------|--------------|-------|--------------|--------------|
| Classes          | 1               | 2            | 3            | Total | UA           | EC           | Classes          | 1                    | 2            | 3            | Total | UA           | EC           |
| 1                | 106             | 30           | 3            | 139   | <b>76,3%</b> | <b>24%</b>   | 1                | 27,3                 | 7,7          | 0,8          | 35,7  | <b>76,3%</b> | <b>23,7%</b> |
| 2                | 5               | 21           |              | 26    | <b>80,8%</b> | <b>19%</b>   | 2                | 1,8                  | 7,7          | 0,0          | 9,6   | <b>80,8%</b> | <b>19,2%</b> |
| 3                | 1               | 23           | 111          | 135   | <b>82,2%</b> | <b>18%</b>   | 3                | 0,4                  | 9,3          | 45,0         | 54,7  | <b>82,2%</b> | <b>17,8%</b> |
| Total            | 112             | 74           | 114          | 300   |              |              | Total            | 29,5                 | 24,7         | 45,7         | 100,0 |              |              |
| <b>PA</b>        | <b>94,6%</b>    | <b>28,4%</b> | <b>97,4%</b> |       |              |              | <b>PA</b>        | <b>92,4%</b>         | <b>31,2%</b> | <b>98,3%</b> |       |              |              |
| <b>EO</b>        | <b>5,4%</b>     | <b>71,6%</b> | <b>2,6%</b>  |       | <b>OA</b>    | <b>79,3%</b> | <b>EO</b>        | <b>7,6%</b>          | <b>68,8%</b> | <b>1,7%</b>  |       | <b>OA</b>    | <b>80,0%</b> |

| RF avec contexte | Matrices brutes |              |              |       |              |              | RF avec contexte | Matrices normalisées |              |              |       |              |              |
|------------------|-----------------|--------------|--------------|-------|--------------|--------------|------------------|----------------------|--------------|--------------|-------|--------------|--------------|
| Classes          | 1               | 2            | 3            | Total | UA           | EC           | Classes          | 1                    | 2            | 3            | Total | UA           | EC           |
| 1                | 97              | 6            | 1            | 104   | <b>93,3%</b> | <b>6,7%</b>  | 1                | 31,0                 | 1,9          | 0,3          | 33,3  | <b>93,3%</b> | <b>6,7%</b>  |
| 2                | 13              | 49           | 7            | 69    | <b>71,0%</b> | <b>29,0%</b> | 2                | 2,3                  | 8,5          | 1,2          | 12,0  | <b>71,0%</b> | <b>29,0%</b> |
| 3                | 2               | 19           | 106          | 127   | <b>83,5%</b> | <b>16,5%</b> | 3                | 0,9                  | 8,2          | 45,7         | 54,8  | <b>83,5%</b> | <b>16,5%</b> |
| Total            | 112             | 74           | 114          | 300   |              |              | Total            | 34,2                 | 18,6         | 47,2         | 100,0 |              |              |
| <b>PA</b>        | <b>86,6%</b>    | <b>66,2%</b> | <b>93,0%</b> |       |              |              | <b>PA</b>        | <b>90,9%</b>         | <b>45,6%</b> | <b>96,8%</b> |       |              |              |
| <b>EO</b>        | <b>13,4%</b>    | <b>33,8%</b> | <b>7,0%</b>  |       | <b>OA</b>    | <b>84,0%</b> | <b>EO</b>        | <b>9,1%</b>          | <b>54,4%</b> | <b>3,2%</b>  |       | <b>OA</b>    | <b>85,2%</b> |

## Chapitre 4

| U-Net     |              | Matrices brutes |              |       |               |              | U-Net     |              | Matrices normalisées |              |       |               |              |
|-----------|--------------|-----------------|--------------|-------|---------------|--------------|-----------|--------------|----------------------|--------------|-------|---------------|--------------|
| Classes   | 1            | 2               | 3            | Total | UA            | EC           | Classes   | 1            | 2                    | 3            | Total | UA            | EC           |
| 1         | 100          |                 |              | 100   | <b>100,0%</b> | <b>0%</b>    | 1         | 32,7         | 0,0                  | 0,0          | 32,7  | <b>100,0%</b> | <b>0,0%</b>  |
| 2         | 12           | 74              | 14           | 100   | <b>74,0%</b>  | <b>26%</b>   | 2         | 1,4          | 8,7                  | 1,6          | 11,8  | <b>74,0%</b>  | <b>26,0%</b> |
| 3         |              |                 | 100          | 100   | <b>100,0%</b> | <b>0%</b>    | 3         | 0,0          | 0,0                  | 55,5         | 55,5  | <b>100,0%</b> | <b>0,0%</b>  |
| Total     | 112          | 74              | 114          | 300   |               |              | Total     | 34,1         | 8,7                  | 57,2         | 100,0 |               |              |
| <b>PA</b> | <b>89,3%</b> | <b>100,0%</b>   | <b>87,7%</b> |       |               |              | <b>PA</b> | <b>95,9%</b> | <b>100,0%</b>        | <b>97,1%</b> |       |               |              |
| <b>EO</b> | <b>10,7%</b> | <b>0,0%</b>     | <b>12,3%</b> |       | <b>OA</b>     | <b>91,3%</b> | <b>EO</b> | <b>4,1%</b>  | <b>0,0%</b>          | <b>2,9%</b>  |       | <b>OA</b>     | <b>96,9%</b> |

| SegNet    |              | Matrices brutes |              |       |              |              | SegNet    |              | Matrices normalisées |              |       |              |              |
|-----------|--------------|-----------------|--------------|-------|--------------|--------------|-----------|--------------|----------------------|--------------|-------|--------------|--------------|
| Classes   | 1            | 2               | 3            | Total | UA           | EC           | Classes   | 1            | 2                    | 3            | Total | UA           | EC           |
| 1         | 92           | 7               | 1            | 100   | <b>92,0%</b> | <b>8%</b>    | 1         | 29,6         | 2,3                  | 0,3          | 32,2  | <b>92,0%</b> | <b>8,0%</b>  |
| 2         | 20           | 62              | 14           | 96    | <b>64,6%</b> | <b>35%</b>   | 2         | 3,0          | 9,4                  | 2,1          | 14,6  | <b>64,6%</b> | <b>35,4%</b> |
| 3         |              | 5               | 99           | 104   | <b>95,2%</b> | <b>5%</b>    | 3         | 0,0          | 2,6                  | 50,6         | 53,2  | <b>95,2%</b> | <b>4,8%</b>  |
| Total     | 112          | 74              | 114          | 300   |              |              | Total     | 32,7         | 14,3                 | 53,1         | 100,0 |              |              |
| <b>PA</b> | <b>82,1%</b> | <b>83,8%</b>    | <b>86,8%</b> |       |              |              | <b>PA</b> | <b>90,7%</b> | <b>66,2%</b>         | <b>95,4%</b> |       |              |              |
| <b>EO</b> | <b>17,9%</b> | <b>16,2%</b>    | <b>13,2%</b> |       | <b>OA</b>    | <b>84,3%</b> | <b>EO</b> | <b>9,3%</b>  | <b>33,8%</b>         | <b>4,6%</b>  |       | <b>OA</b>    | <b>89,7%</b> |

| Resnet-<br>Unet |              | Matrices brutes |              |       |              |              | Resnet-<br>Unet |              | Matrices normalisées |              |       |              |              |
|-----------------|--------------|-----------------|--------------|-------|--------------|--------------|-----------------|--------------|----------------------|--------------|-------|--------------|--------------|
| Classes         | 1            | 2               | 3            | Total | UA           | EC           | Classes         | 1            | 2                    | 3            | Total | UA           | EC           |
| 1               | 108          | 8               |              | 116   | <b>93,1%</b> | <b>7%</b>    | 1               | 32,2         | 2,4                  | 0,0          | 34,6  | <b>93,1%</b> | <b>6,9%</b>  |
| 2               | 4            | 62              | 12           | 78    | <b>79,5%</b> | <b>21%</b>   | 2               | 0,5          | 8,5                  | 1,6          | 10,7  | <b>79,5%</b> | <b>20,5%</b> |
| 3               |              | 4               | 102          | 106   | <b>96,2%</b> | <b>4%</b>    | 3               | 0,0          | 2,1                  | 52,7         | 54,7  | <b>96,2%</b> | <b>3,8%</b>  |
| Total           | 112          | 74              | 114          | 300   |              |              | Total           | 32,7         | 12,9                 | 54,3         | 100,0 |              |              |
| <b>PA</b>       | <b>96,4%</b> | <b>83,8%</b>    | <b>89,5%</b> |       |              |              | <b>PA</b>       | <b>98,3%</b> | <b>65,6%</b>         | <b>97,0%</b> |       |              |              |
| <b>EO</b>       | <b>3,6%</b>  | <b>16,2%</b>    | <b>10,5%</b> |       | <b>OA</b>    | <b>90,7%</b> | <b>EO</b>       | <b>1,7%</b>  | <b>34,4%</b>         | <b>3,0%</b>  |       | <b>OA</b>    | <b>93,4%</b> |




Figure 61 : comparaison de la carte photo-interprétée de Ziama 2021 (en haut à gauche), les cartes issues des méthodologies Random Forest du chapitre 3 appliquées à 2021 (en haut, au milieu et à droite) et les cartes issues des 3 réseaux deep learning U-Net, SegNet et Resnet-Unet du chapitre 4. Les précisions globales (OA) de la validation externe sont données. A gauche, l'image Sentinel-2 2021 en composition colorée PIR/MIR/R.

Une comparaison similaire des méthodologies est effectuée sur le massif de Nimba en 2021. Eprouver les méthodologies sur Nimba permet d'évaluer et de démontrer leur faisabilité sur un cas nouveau de grande ampleur. Les matrices brutes et normalisées de la validation externe sont exposées dans le tableau 23. Elles comparent :

- i) la carte de Nimba 2021, construite par la méthode de photo-interprétation décrite dans le chapitre 2,
- ii) les résultats de classification des méthodes Random Forest contextuelle et non-contextuelle du chapitre 3 appliquées à l'image Sentinel-2 2021, lorsque le modèle s'entraîne sur Ziama seul ;
- iii) les résultats de classification des méthodes Random Forest contextuelle et non-contextuelle, lorsque le modèle s'entraîne sur le massif de Ziama et 1,6% de la surface de Nimba ;
- iv) les résultats issus des 3 réseaux CNN U-Net, SegNet et Resnet-Unet utilisés dans le chapitre 4.

D'abord, les méthodologies Random Forest, contextuelle et non contextuelle, utilisant Ziama et une faible proportion de Nimba (1,6%) dans leur apprentissage montrent une nette amélioration dans les scores de performance (précisions globales respectivement de 75,3% et 81,4%), comparé aux approches qui n'impliquent que Ziama dans leur apprentissage (précisions globales respectivement de 52,1% et 47,4%). Ceci montre que la méthodologie développée dans le chapitre 3 requiert un coût minimum de photo-interprétation pour la classification d'une nouvelle région.

Par ailleurs, parmi les modèles qui n'impliquent que Ziama dans leur apprentissage, la méthode non contextuelle montre une précision globale de 52,1% qui semble meilleure que la méthode contextuelle (47,4%), mais les précisions utilisateur et producteur de la classe 'forêt dégradée' sont nulles avec la méthode non contextuelle (en rouge dans le tableau 23). Ceci indique que sans voisinage pixellaire dans l'algorithme, le modèle de classification est incapable de détecter la forêt dégradée du mont Nimba, sans un minimum d'apprentissage sur la zone. En outre, la méthodologie contextuelle montre une meilleure précision globale (81,4%) que celle non contextuelle (75,3%), avec un apprentissage sur Ziama et Nimba.

Enfin, les 3 modèles de réseaux neuronaux convolutifs parviennent à de meilleures précisions globales pour la détection des forêts dégradées, sans apprentissage sur le massif. La meilleure approche demeure l'emploi du modèle U-Net, avec une précision globale de 91,5% et les plus hautes valeurs de précisions utilisateur et producteur pour la classe 'forêt dégradée', respectivement 75,0% et 84,5% (en vert dans le tableau 23). Les résultats cartographiques sont illustrés dans la figure 62.

En conclusion, les meilleurs résultats sur Nimba sont obtenus avec le modèle U-Net entraîné intégralement sur Ziama, puis avec la photo-interprétation. Les deux autres CNN et la méthode RF, si elle est entraînée légèrement sur ce nouveau site, offrent des performances à peu près similaires, mais un peu moins bonnes que U-Net et la photo-interprétation.

Le modèle U-Net a donc été choisi pour réaliser la mise à jour des classes forestières dans le cadre de l'actualisation (année 2021) des données du projet ZAEG, et remplace la méthode précédente basée sur la photo-interprétation mono-date. Ceci répond à la première priorité de la thèse qui consiste à concevoir une méthodologie fiable, robuste et reproductible de détection des forêts dégradées sur des grands espaces, pour apporter une meilleure connaissance aux institutions étatiques et autres utilisateurs finaux de l'état actuel et réel des forêts tropicales.

Tableau 23 : matrices d'erreur brutes et normalisées pour la carte photo-interprétée **Nimba** 2021, les 3 modèles CNN (U-Net, SegNet, Resnet-UNet) et les 4 modèles Random Forest avec et sans contexte régional dans l'algorithme, avec et sans Nimba dans l'apprentissage. UA : précision utilisateur, PA : précision producteur, EC : erreur de commission, EO : erreur d'omission, OA : précision globale.

## Chapitre 2

| PI 2021 | Matrices brutes |              |              |       |              |              | PI 2021 | Matrices normalisées |              |              |       |              |              |
|---------|-----------------|--------------|--------------|-------|--------------|--------------|---------|----------------------|--------------|--------------|-------|--------------|--------------|
| Classes | 1               | 2            | 3            | Total | UA           | EC           | Classes | 1                    | 2            | 3            | Total | UA           | EC           |
| 1       | 95              | 5            | 2            | 102   | <b>93,1%</b> | <b>7%</b>    | 1       | 14,5                 | 0,8          | 0,3          | 15,6  | <b>93,1%</b> | <b>6,9%</b>  |
| 2       | 5               | 68           | 17           | 90    | <b>75,6%</b> | <b>24%</b>   | 2       | 1,1                  | 14,7         | 3,7          | 19,5  | <b>75,6%</b> | <b>24,4%</b> |
| 3       |                 | 9            | 99           | 108   | <b>91,7%</b> | <b>8%</b>    | 3       | 0,0                  | 5,4          | 59,5         | 64,9  | <b>91,7%</b> | <b>8,3%</b>  |
| Total   | 100             | 82           | 118          | 300   |              |              | Total   | 15,6                 | 20,9         | 63,5         | 100,0 |              |              |
| PA      | <b>95,0%</b>    | <b>82,9%</b> | <b>83,9%</b> |       |              |              | PA      | <b>93,1%</b>         | <b>70,4%</b> | <b>93,7%</b> |       |              |              |
| EO      | <b>5,0%</b>     | <b>17,1%</b> | <b>16,1%</b> |       | OA           | <b>87,3%</b> | EO      | <b>6,9%</b>          | <b>29,6%</b> | <b>6,3%</b>  |       | OA           | <b>88,8%</b> |

## Chapitre 3

| RF sans contexte | Matrices brutes |               |              |       |              |              | Nimba 0% | RF sans contexte | Matrices normalisées |               |              |       |              |               | Nimba 0% |
|------------------|-----------------|---------------|--------------|-------|--------------|--------------|----------|------------------|----------------------|---------------|--------------|-------|--------------|---------------|----------|
| Classes          | 1               | 2             | 3            | Total | UA           | EC           |          | Classes          | 1                    | 2             | 3            | Total | UA           | EC            |          |
| 1                | 60              | 12            | 2            | 74    | <b>81,1%</b> | <b>19%</b>   |          | 1                | 9,3                  | 1,9           | 0,3          | 11,4  | <b>81,1%</b> | <b>18,9%</b>  |          |
| 2                | 1               |               |              | 1     | <b>0,0%</b>  | <b>100%</b>  |          | 2                | 5,5                  | 0,0           | 0,0          | 5,5   | <b>0,0%</b>  | <b>100,0%</b> |          |
| 3                | 39              | 70            | 116          | 225   | <b>51,6%</b> | <b>48%</b>   |          | 3                | 14,4                 | 25,9          | 42,8         | 83,1  | <b>51,6%</b> | <b>48,4%</b>  |          |
| Total            | 100             | 82            | 118          | 300   |              |              |          | Total            | 29,1                 | 27,7          | 43,2         | 100,0 |              |               |          |
| PA               | <b>60,0%</b>    | <b>0,0%</b>   | <b>98,3%</b> |       |              |              |          | PA               | <b>31,8%</b>         | <b>0,0%</b>   | <b>99,3%</b> |       |              |               |          |
| EO               | <b>40,0%</b>    | <b>100,0%</b> | <b>1,7%</b>  |       | OA           | <b>58,7%</b> |          | EO               | <b>68,2%</b>         | <b>100,0%</b> | <b>0,7%</b>  |       | OA           | <b>52,1%</b>  |          |

| RF avec contexte | Matrices brutes |              |               |       |              |              | Nimba 0% | RF avec contexte | Matrices normalisées |              |               |       |              |              | Nimba 0% |
|------------------|-----------------|--------------|---------------|-------|--------------|--------------|----------|------------------|----------------------|--------------|---------------|-------|--------------|--------------|----------|
| Classes          | 1               | 2            | 3             | Total | UA           | EC           |          | Classes          | 1                    | 2            | 3             | Total | UA           | EC           |          |
| 1                | 28              | 2            |               | 30    | <b>93,3%</b> | <b>6,7%</b>  |          | 1                | 3,4                  | 0,2          | 0,0           | 3,6   | <b>93,3%</b> | <b>6,7%</b>  |          |
| 2                | 23              | 3            |               | 26    | <b>11,5%</b> | <b>88,5%</b> |          | 2                | 6,3                  | 0,8          | 0,0           | 7,1   | <b>11,5%</b> | <b>88,5%</b> |          |
| 3                | 49              | 77           | 118           | 244   | <b>48,4%</b> | <b>51,6%</b> |          | 3                | 17,9                 | 28,2         | 43,2          | 89,3  | <b>48,4%</b> | <b>51,6%</b> |          |
| Total            | 100             | 82           | 118           | 300   |              |              |          | Total            | 27,6                 | 29,2         | 43,2          | 100,0 |              |              |          |
| PA               | <b>28,0%</b>    | <b>3,7%</b>  | <b>100,0%</b> |       |              |              |          | PA               | <b>12,2%</b>         | <b>2,8%</b>  | <b>100,0%</b> |       |              |              |          |
| EO               | <b>72,0%</b>    | <b>96,3%</b> | <b>0,0%</b>   |       | OA           | <b>49,7%</b> |          | EO               | <b>87,8%</b>         | <b>97,2%</b> | <b>0,0%</b>   |       | OA           | <b>47,4%</b> |          |

| RF sans contexte | Matrices brutes |              |              |       |              |              | Nimba 1,6% | RF sans contexte | Matrices normalisées |              |              |       |              |              | Nimba 1,6% |
|------------------|-----------------|--------------|--------------|-------|--------------|--------------|------------|------------------|----------------------|--------------|--------------|-------|--------------|--------------|------------|
| Classes          | 1               | 2            | 3            | Total | UA           | EC           |            | Classes          | 1                    | 2            | 3            | Total | UA           | EC           |            |
| 1                | 86              | 9            | 1            | 96    | <b>89,6%</b> | <b>10%</b>   |            | 1                | 13,0                 | 1,4          | 0,2          | 14,5  | <b>89,6%</b> | <b>10,4%</b> |            |
| 2                | 11              | 42           | 13           | 66    | <b>63,6%</b> | <b>36%</b>   |            | 2                | 3,0                  | 11,6         | 3,6          | 18,3  | <b>63,6%</b> | <b>36,4%</b> |            |
| 3                | 3               | 31           | 104          | 138   | <b>75,4%</b> | <b>25%</b>   |            | 3                | 1,5                  | 15,1         | 50,6         | 67,2  | <b>75,4%</b> | <b>24,6%</b> |            |
| Total            | 100             | 82           | 118          | 300   |              |              |            | Total            | 17,5                 | 28,1         | 54,4         | 100,0 |              |              |            |
| PA               | <b>86,0%</b>    | <b>51,2%</b> | <b>88,1%</b> |       |              |              |            | PA               | <b>74,3%</b>         | <b>41,4%</b> | <b>93,1%</b> |       |              |              |            |
| EO               | <b>14,0%</b>    | <b>48,8%</b> | <b>11,9%</b> |       | OA           | <b>77,3%</b> |            | EO               | <b>25,7%</b>         | <b>58,6%</b> | <b>6,9%</b>  |       | OA           | <b>75,3%</b> |            |

| RF avec contexte | Matrices brutes |              |              |       |              |              | Nimba 1,6% |              | RF avec contexte | Matrices normalisées |              |              |       |              |              | Nimba 1,6% |              |
|------------------|-----------------|--------------|--------------|-------|--------------|--------------|------------|--------------|------------------|----------------------|--------------|--------------|-------|--------------|--------------|------------|--------------|
| Classes          | 1               | 2            | 3            | Total | UA           | EC           |            |              | Classes          | 1                    | 2            | 3            | Total | UA           | EC           |            |              |
| 1                | 90              | 8            | 1            | 99    | <b>90,9%</b> | <b>9,1%</b>  |            |              | 1                | 13,9                 | 1,2          | 0,2          | 15,3  | <b>90,9%</b> | <b>9,1%</b>  |            |              |
| 2                | 7               | 53           | 12           | 72    | <b>73,6%</b> | <b>26,4%</b> |            |              | 2                | 1,8                  | 13,6         | 3,1          | 18,4  | <b>73,6%</b> | <b>26,4%</b> |            |              |
| 3                | 3               | 21           | 105          | 129   | <b>81,4%</b> | <b>18,6%</b> |            |              | 3                | 1,5                  | 10,8         | 53,9         | 66,2  | <b>81,4%</b> | <b>18,6%</b> |            |              |
| Total            | 100             | 82           | 118          | 300   |              |              |            |              | Total            | 17,3                 | 25,6         | 57,1         | 100,0 |              |              |            |              |
| PA               | <b>90,0%</b>    | <b>64,6%</b> | <b>89,0%</b> |       |              |              |            |              | PA               | <b>80,7%</b>         | <b>53,0%</b> | <b>94,4%</b> |       |              |              |            |              |
| EO               | <b>10,0%</b>    | <b>35,4%</b> | <b>11,0%</b> |       |              |              | OA         | <b>82,7%</b> | EO               | <b>19,3%</b>         | <b>47,0%</b> | <b>5,6%</b>  |       |              |              | OA         | <b>81,4%</b> |

#### Chapitre 4

| U-Net   | Matrices brutes |              |              |       |              |            | U-Net   | Matrices normalisées |              |              |       |              |              |              |
|---------|-----------------|--------------|--------------|-------|--------------|------------|---------|----------------------|--------------|--------------|-------|--------------|--------------|--------------|
| Classes | 1               | 2            | 3            | Total | UA           | EC         | Classes | 1                    | 2            | 3            | Total | UA           | EC           |              |
| 1       | 96              | 3            | 1            | 100   | <b>96,0%</b> | <b>4%</b>  | 1       | 14,1                 | 0,4          | 0,1          | 14,7  | <b>96,0%</b> | <b>4,0%</b>  |              |
| 2       | 4               | 75           | 21           | 100   | <b>75,0%</b> | <b>25%</b> | 2       | 0,9                  | 16,2         | 4,5          | 21,7  | <b>75,0%</b> | <b>25,0%</b> |              |
| 3       |                 | 4            | 96           | 100   | <b>96,0%</b> | <b>4%</b>  | 3       | 0,0                  | 2,5          | 61,1         | 63,6  | <b>96,0%</b> | <b>4,0%</b>  |              |
| Total   | 100             | 82           | 118          | 300   |              |            | Total   | 15,0                 | 19,2         | 65,8         | 100,0 |              |              |              |
| PA      | <b>96,0%</b>    | <b>91,5%</b> | <b>81,4%</b> |       |              |            | PA      | <b>94,2%</b>         | <b>84,5%</b> | <b>92,9%</b> |       |              |              |              |
| EO      | <b>4,0%</b>     | <b>8,5%</b>  | <b>18,6%</b> |       |              |            | EO      | <b>5,8%</b>          | <b>15,5%</b> | <b>7,1%</b>  |       |              | OA           | <b>91,5%</b> |

| SegNet  | Matrices brutes |              |              |       |              |            | SegNet  | Matrices normalisées |              |              |       |              |              |              |
|---------|-----------------|--------------|--------------|-------|--------------|------------|---------|----------------------|--------------|--------------|-------|--------------|--------------|--------------|
| Classes | 1               | 2            | 3            | Total | UA           | EC         | Classes | 1                    | 2            | 3            | Total | UA           | EC           |              |
| 1       | 74              | 5            |              | 79    | <b>93,7%</b> | <b>6%</b>  | 1       | 10,0                 | 0,7          | 0,0          | 10,6  | <b>93,7%</b> | <b>6,3%</b>  |              |
| 2       | 25              | 54           | 10           | 89    | <b>60,7%</b> | <b>39%</b> | 2       | 5,7                  | 12,4         | 2,3          | 20,4  | <b>60,7%</b> | <b>39,3%</b> |              |
| 3       | 1               | 23           | 108          | 132   | <b>81,8%</b> | <b>18%</b> | 3       | 0,5                  | 12,0         | 56,4         | 68,9  | <b>81,8%</b> | <b>18,2%</b> |              |
| Total   | 100             | 82           | 118          | 300   |              |            | Total   | 16,2                 | 25,1         | 58,7         | 100,0 |              |              |              |
| PA      | <b>74,0%</b>    | <b>65,9%</b> | <b>91,5%</b> |       |              |            | PA      | <b>61,4%</b>         | <b>49,4%</b> | <b>96,1%</b> |       |              |              |              |
| EO      | <b>26,0%</b>    | <b>34,1%</b> | <b>8,5%</b>  |       |              |            | EO      | <b>38,6%</b>         | <b>50,6%</b> | <b>3,9%</b>  |       |              | OA           | <b>78,8%</b> |

| Resnet-Unet | Matrices brutes |              |              |       |              |            | Resnet-Unet | Matrices normalisées |              |              |       |              |              |              |
|-------------|-----------------|--------------|--------------|-------|--------------|------------|-------------|----------------------|--------------|--------------|-------|--------------|--------------|--------------|
| Classes     | 1               | 2            | 3            | Total | UA           | EC         | Classes     | 1                    | 2            | 3            | Total | UA           | EC           |              |
| 1           | 90              | 7            | 2            | 99    | <b>90,9%</b> | <b>9%</b>  | 1           | 13,4                 | 1,0          | 0,3          | 14,7  | <b>90,9%</b> | <b>9,1%</b>  |              |
| 2           | 9               | 63           | 15           | 87    | <b>72,4%</b> | <b>28%</b> | 2           | 2,0                  | 14,2         | 3,4          | 19,7  | <b>72,4%</b> | <b>27,6%</b> |              |
| 3           | 1               | 12           | 101          | 114   | <b>88,6%</b> | <b>11%</b> | 3           | 0,6                  | 6,9          | 58,1         | 65,6  | <b>88,6%</b> | <b>11,4%</b> |              |
| Total       | 100             | 82           | 118          | 300   |              |            | Total       | 16,0                 | 22,2         | 61,8         | 100,0 |              |              |              |
| PA          | <b>90,0%</b>    | <b>76,8%</b> | <b>85,6%</b> |       |              |            | PA          | <b>83,7%</b>         | <b>64,2%</b> | <b>94,0%</b> |       |              |              |              |
| EO          | <b>10,0%</b>    | <b>23,2%</b> | <b>14,4%</b> |       |              |            | EO          | <b>16,3%</b>         | <b>35,8%</b> | <b>6,0%</b>  |       |              | OA           | <b>85,8%</b> |




Figure 62 : comparaison de la carte photo-interprétée de Nimba 2021 (2<sup>e</sup> ligne, à gauche), les cartes issues des méthodologies Random Forest du chapitre 3 appliquées à l'image S2 2021 et les cartes issues des 3 réseaux deep learning U-Net, SegNet et Resnet-Unet du chapitre 4 (dernière ligne). Les précisions globales (OA) de la validation externe sont indiquées. En haut à gauche, l'image Sentinel-2 2021 en composition colorée PIR/MIR/R.

## 5.2. Perspectives

### 5.2.1. Détection des forêts dégradées dans un autre contexte

La généralisation à d'autres contextes forestiers et climatiques nécessite d'être étudiée. Le modèle développé dans le chapitre 4 parvient à détecter les forêts dégradées sur un site jamais vu comme Nimba car la forme de dégradation y est de la même nature que sur les sites d'apprentissage. Pourtant, il existe des formes variées de dégradation et de forêts dégradées, dont on ignore si les méthodes développées dans la thèse peuvent s'y adapter. En République du Congo par exemple, les forêts tropicales équatoriales se caractérisent par plus de 2 000 mm de pluie par an, répartis uniformément tout au long de l'année. Ces forêts sont proches de l'équateur, où on observe très peu de variations thermiques saisonnières, et sont sempervirentes. Elles sont par conséquent différentes des forêts de mousson de Guinée. Les forêts dégradées congolaises peuvent prendre différentes formes :

- i) Les forêts endommagées par la construction de routes (fig. 63). Dans ce cas précis, la dégradation des forêts est généralement un tremplin vers la déforestation. Une fois qu'une entreprise forestière commence à construire des routes dans une forêt, d'autres suivent : mineurs, éleveurs et agriculteurs qui n'y auraient pas eu accès autrement. Les améliorations d'accessibilité, comme les routes, jouent un rôle important dans l'augmentation des perturbations forestières locales ; plus d'accessibilité implique plus de perturbations.
- ii) Les forêts dégradées peuvent aussi être définies comme des forêts secondaires mono-spécifiques, résultat de la régénération forestière après une coupe à blanc (fig. 63). La forêt est constituée d'espèces endémiques locales et est encore dense et intacte sur une image Landsat de 2001, avant une coupe à blanc survenue en 2014. On observe ensuite une régénération forestière sur l'image Sentinel-2 2020 dont la domination du Parasolier (*Musanga Cecropioides*), essence héliophile, montre une radiométrie différente et une texture très homogène, comparativement aux forêts naturelles adultes environnantes, ce qui suggère qu'elles sont équiennes. Cette 2<sup>ème</sup> définition est également retrouvée dans Koubouana et al. (2018). Les auteurs discriminent cinq types de forêts dont les forêts dégradées à *Musanga cecropioides* et à *Macaranga* spp.



Figure 63 : deux formes de forêts dégradées en République du Congo. A gauche : les cimes de la strate arborescente ne sont plus contiguës et sont toujours constituées d'espèces d'arbres endémiques locales. A droite : régénération exclusive de la forêt à croissance rapide de *Musanga Cecropioides*, après un événement de déforestation.



Le modèle d'apprentissage profond entraîné sur les massifs guinéens détecte difficilement les forêts dégradées dans le contexte forestier et climatique congolais. Vu les taux de précipitations il est peu probable qu'un stress hydrique apparaisse, même dans les forêts dégradées, rendant la bande MIR moins sensible à la dégradation. En restreignant le jeu de données d'entraînement au Congo, les bandes Sentinel-2 brutes et le MSI suffisent au nouveau modèle CNN pour atteindre une précision globale au-dessus de 90%. Ceci indique que pour une autre modalité de dégradation, il est nécessaire de ré-interpréter et fournir une nouvelle base d'images d'apprentissage. Face à d'autres contextes forestiers et/ou climatiques, il faut donc faire appel à une nouvelle série d'échantillons d'entraînement ; ceci peut être rendu possible grâce aux bases de données existantes comme le catalogue de Google Earth Engine, en conservant la méthodologie d'apprentissage en profondeur.

### **5.2.2. Enrichissement des données et amélioration de la méthodologie**

Le satellite BIOMASS de l'ESA, dont le lancement est prévu pour 2023, a notamment pour mission d'évaluer le volume global de la biomasse tropicale de la planète afin d'estimer les quantités de carbone stockées et les flux de celui-ci. Le capteur utilisera pour la première fois dans l'espace un radar à synthèse d'ouverture en bande P (longueur d'onde de 60 cm). Le capteur BIOMASS devrait établir des cartes de la hauteur et du volume des arbres, et donc fournir des informations sur la biomasse forestière mondiale et la teneur en carbone et combler ainsi le vide actuel dans le suivi de la densité de la biomasse forestière. La mission GEDI (ou Global Ecosystem Dynamics Investigation) est une mission de la NASA visant à mesurer comment la déforestation a contribué aux concentrations de CO<sub>2</sub> dans l'atmosphère. Un LIDAR a été attaché à la Station spatiale internationale (ISS) pour fournir les premières observations mondiales à haute résolution de la structure verticale des forêts. Cela devrait permettre aux scientifiques de cartographier les habitats et la biomasse, en particulier sous les tropiques. GEDI comme BIOMASS peuvent récupérer la structure tridimensionnelle des forêts et capturer les changements de la biomasse forestière dus aux perturbations. Ces informations sont particulièrement utiles pour la quantification des changements de la biomasse liés aux perturbations, et pour la caractérisation des perturbations forestières. La perspective d'utiliser les données de Sentinel-2 combinées à celles issues des missions BIOMASS et GEDI dans des modèles d'apprentissage profond est prometteuse pour la cartographie mais aussi pour la caractérisation des forêts dégradées.

Nous avons initié des tests prometteurs de fusion de données Sentinel-2 et de données radar ALOS-PALSAR 2 pour la détection de forêts dégradées. En effet, lorsque la dégradation forestière affecte le sous-bois ou bien consiste en un abattage sélectif, elle est associée à un changement dans la structure de la forêt sous la canopée. L'interaction du rayonnement micro-ondes avec la végétation est fortement liée à la longueur d'onde utilisée, variant de la bande X (~ 3 cm), C (~ 6 cm), S (~ 15 cm), L (~ 24 cm) à la bande P (~ 69 cm). Notre choix s'est porté sur l'onde radar bande L qui peut traverser le couvert forestier, interagir avec les branches et les tiges et communiquer des informations sur la structure de la forêt. C'est par ailleurs pourquoi le suivi de la dégradation des forêts tropicales est surtout étudié en radar bande L. C'est le cas des travaux de Reiche et al. (2013), où les images radar ALOS-PALSAR ont été combinées

aux données optiques Landsat. Joshi et al. (2015) détectent également les processus de déforestation, de dégradation des forêts et de dynamique de succession, en utilisant la rétrodiffusion en bande L d'ALOS PALSAR par une série de seuillages annuels (2007 à 2010). Les auteurs parviennent à un taux de détection faible, mais significatif, de la dégradation due à l'exploitation forestière sélective et à petite échelle au Pérou, dans la région de Madre de Dios. Selon les auteurs, l'une des principales limitations réside dans le fait que la rétrodiffusion peut avoir une faible sensibilité aux pertes de biomasse de faible magnitude dans les zones à forte biomasse en raison de la saturation du signal (généralement 100 Mg/ha pour les radars en bande L). Aussi, les perturbations de la structure de la végétation doivent être suffisamment importantes et pertinentes à la résolution de 30 m (comme l'élimination d'un grand arbre), pour que la détection soit possible. De manière générale, la résolution spatiale de 30 m et les erreurs liées à la saturation limitent grandement l'utilisation du radar seul pour la détection des forêts dégradées en Guinée.

Nos essais se sont orientés sur l'utilisation jointe des données radar et optiques. D'une part, 5 images Sentinel-2 du jeu de données d'entraînement du chapitre 4 ont été sélectionnées et seul l'indice MSI a été généré à partir de ces images. Il s'agit de celles acquises en 2015, 2017, 2018, 2019 et le 2 février 2020. D'autre part, au lieu d'additionner les néocanaux biophysiques LAI et CWC, des images mosaïques annuelles radar ALOS-PALSAR 2 ont été ajoutées. Cinq mosaïques PALSAR 2 datées de 2015, 2017, 2018, 2019 et 2020 ont été empilées aux images S2 correspondantes (fig. 64). Ces images PALSAR 2 ont été rééchantillonnées à 10 m. Elles ont été calibrées, c'est-à-dire que les comptes numériques ont été convertis vers le coefficient de rétrodiffusion gamma.

La précision globale obtenue de 90,0% indique qu'avec peu de données photo-interprétées et annotées, la donnée radar en bande L paraît apporter une information supplémentaire aux données optiques Sentinel-2, sur les changements structurels que manifestent les forêts dégradées en Guinée. La fusion Sentinel-2 et ALOS-PALSAR 2 semble être un axe de recherche prometteur.

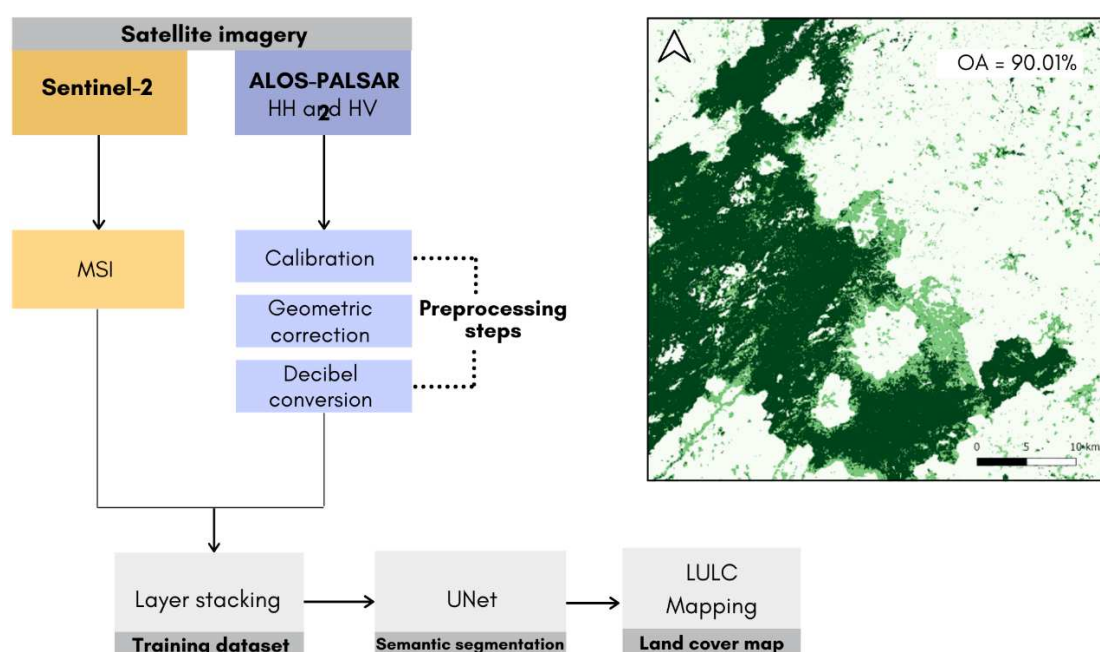


Figure 64 : fusion d'images radar ALOS-PALSAR 2 et optiques Sentinel-2.



## Bibliographie

- Alexander, S., Nelson, C.R., Aronson, J., Lamb, D., Cliquet, A., Erwin, K.L., Finlayson, C.M., de Groot, R.S., Harris, J.A., Higgs, E.S., Hobbs, R.J., Robin Lewis, R.R., Martinez, D., Murcia, C., 2011. Opportunities and Challenges for Ecological Restoration within REDD+. *Restoration Ecology* 19, 683–689. <https://doi.org/10.1111/j.1526-100X.2011.00822.x>
- Alvira, D., Putz, F.E., Fredericksen, T.S., 2004. Liana loads and post-logging liana densities after liana cutting in a lowland forest in Bolivia. *Forest Ecology and Management* 190, 73–86. <https://doi.org/10.1016/j.foreco.2003.10.007>
- Angelsen, A., Brockhaus, M., Center for International Forestry Research (Eds.), 2009. Realising REDD+: national strategy and policy options. Center for International Forestry Research, Bogor, Indonesia.
- Aryal, R.R., Wespestad, C., Kennedy, R., Dilger, J., Dyson, K., Bullock, E., Khanal, N., Kono, M., Poortinga, A., Saah, D., Tenneson, K., 2021. Lessons Learned While Implementing a Time-Series Approach to Forest Canopy Disturbance Detection in Nepal. *Remote Sensing* 13, 2666. <https://doi.org/10.3390/rs13142666>
- Asner, G.P., Lobell, D.B., 2000. A Biogeophysical Approach for Automated SWIR Unmixing of Soils and Vegetation. *Remote Sensing of Environment* 74, 99–112. [https://doi.org/10.1016/S0034-4257\(00\)00126-7](https://doi.org/10.1016/S0034-4257(00)00126-7)
- Asner, G.P., Powell, G.V.N., Mascaró, J., Knapp, D.E., Clark, J.K., Jacobson, J., Kennedy-Bowdoin, T., Balaji, A., Paez-Acosta, G., Victoria, E., Secada, L., Valqui, M., Hughes, R.F., 2010. High-resolution forest carbon stocks and emissions in the Amazon. *Proceedings of the National Academy of Sciences* 107, 16738–16742. <https://doi.org/10.1073/pnas.1004875107>
- Aweto, A.O., 2001. Impact of single species tree plantations on nutrient cycling in West Africa. *International Journal of Sustainable Development & World Ecology* 8, 356–368. <https://doi.org/10.1080/13504500109470093>
- Badrinarayanan, V., Kendall, A., Cipolla, R., 2017. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Trans. Pattern Anal. Mach. Intell.* 39, 2481–2495. <https://doi.org/10.1109/TPAMI.2016.2644615>
- Bartholomé, E., Belward, A.S., 2005. GLC2000: a new approach to global land cover mapping from Earth observation data. *International Journal of Remote Sensing* 26, 1959–1977. <https://doi.org/10.1080/01431160412331291297>
- Bewernick, T., 2016. Mapping Forest Degradation in the Mau Forest Complex Using NDFI Time Series [WWW Document]. CIFOR. URL [https://www2.cifor.org/wpsite/wp-content/uploads/watertowers/\(Bewernick%202016\)%20Mapping%20forest%20degradation%20in%20the%20Mau%20Forest%20Complex%20using%20NDFI%20time%20series.pdf](https://www2.cifor.org/wpsite/wp-content/uploads/watertowers/(Bewernick%202016)%20Mapping%20forest%20degradation%20in%20the%20Mau%20Forest%20Complex%20using%20NDFI%20time%20series.pdf)
- Boulvert, Y., 2003. La Guinée: atouts et handicaps au seuil du troisième millénaire. *Géographie-Paris Société de géographie*.
- Bourgoin, C., Betbeder, J., Couteron, P., Blanc, L., Dessard, H., Oszwald, J., Le Roux, R., Cornu, G., Reymondin, L., Mazzei, L., Sist, P., Läderach, P., Gond, V., 2020. UAV-based canopy textures assess changes in forest structure from long-term degradation. *Ecological Indicators* 115, 106386. <https://doi.org/10.1016/j.ecolind.2020.106386>
- Bourgoin, C., Blanc, L., Bailly, J.-S., Cornu, G., Berenguer, E., Oszwald, J., Tritsch, I., Laurent, F., Hasan, A., Sist, P., Gond, V., 2018. The Potential of Multisource Remote Sensing for Mapping the Biomass of a Degraded Amazonian Forest. *Forests* 9, 303. <https://doi.org/10.3390/f9060303>

- Bouvet, A., Mermoz, S., Ballère, M., Koleck, T., Le Toan, T., 2018. Use of the SAR Shadowing Effect for Deforestation Detection with Sentinel-1 Time Series. *Remote Sensing* 10, 1250. <https://doi.org/10.3390/rs10081250>
- Breda, N.J.J., 2003. Ground-based measurements of leaf area index: a review of methods, instruments and current controversies. *Journal of Experimental Botany* 54, 2403–2417. <https://doi.org/10.1093/jxb/erg263>
- Breiman, L., 2001. Random forests. *Machine learning* 45.1, 5–32.
- Briant, G., Gond, V., Laurance, S.G.W., 2010. Habitat fragmentation and the desiccation of forest canopies: A case study from eastern Amazonia. *Biological Conservation* 143, 2763–2769. <https://doi.org/10.1016/j.biocon.2010.07.024>
- Broadbent, E.N., Asner, G.P., Keller, M., Knapp, D.E., Oliveira, P.J.C., Silva, J.N., 2008. Forest fragmentation and edge effects from deforestation and selective logging in the Brazilian Amazon. *Biological Conservation* 141, 1745–1757. <https://doi.org/10.1016/j.biocon.2008.04.024>
- Bullock, E.L., Nolte, C., Reboredo Segovia, A.L., Woodcock, C.E., 2020a. Ongoing forest disturbance in Guatemala’s protected areas. *Remote Sens Ecol Conserv* 6, 141–152. <https://doi.org/10.1002/rse2.130>
- Bullock, E.L., Woodcock, C.E., 2021. Carbon loss and removal due to forest disturbance and regeneration in the Amazon. *Science of The Total Environment* 764, 142839. <https://doi.org/10.1016/j.scitotenv.2020.142839>
- Bullock, E.L., Woodcock, C.E., Olofsson, P., 2020b. Monitoring tropical forest degradation using spectral unmixing and Landsat time series analysis. *Remote Sensing of Environment* 238, 110968. <https://doi.org/10.1016/j.rse.2018.11.011>
- Bullock, E.L., Woodcock, C.E., Souza, C., Olofsson, P., 2020c. Satellite-based estimates reveal widespread forest degradation in the Amazon. *Glob Change Biol* 26, 2956–2969. <https://doi.org/10.1111/gcb.15029>
- Camara, A., Dugué, P., Cheylan, J.-P., Kalms, J.-M., 2009. De la forêt naturelle aux agroforêts en Guinée forestière. *Cahiers Agricultures* 18, 425–432. <https://doi.org/10.1684/agr.2009.0325>
- Camara, A.A., Dugué, P., de Foresta, H., 2012. Transformation des mosaïques de forêt-savane par des pratiques agroforestières en Afrique subsaharienne (Guinée et Cameroun). *cybergeo*. <https://doi.org/10.4000/cybergeo.25588>
- Canadell, J.G., Raupach, M.R., Houghton, R.A., 2009. Anthropogenic CO<sub>2</sub> emissions in Africa 6.
- Cao, K., Zhang, X., 2020. An Improved Res-UNet Model for Tree Species Classification Using Airborne High-Resolution Images. *Remote Sensing* 12, 1128. <https://doi.org/10.3390/rs12071128>
- Ceccato, P., Flasse, S., Tarantola, S., Jacquemoud, S., Grégoire, J.-M., 2001. Detecting vegetation leaf water content using reflectance in the optical domain. *Remote Sensing of Environment* 77, 22–33. [https://doi.org/10.1016/S0034-4257\(01\)00191-2](https://doi.org/10.1016/S0034-4257(01)00191-2)
- Charng, J., Xiao, D., Mehdizadeh, M., Attia, M.S., Arunachalam, S., Lamey, T.M., Thompson, J.A., McLaren, T.L., De Roach, J.N., Mackey, D.A., Frost, S., Chen, F.K., 2020. Deep learning segmentation of hyperautofluorescent fleck lesions in Stargardt disease. *Sci Rep* 10, 16491. <https://doi.org/10.1038/s41598-020-73339-y>
- Chazdon, R.L., Brancalion, P.H.S., Laestadius, L., Bennett-Curry, A., Buckingham, K., Kumar, C., Moll-Rocek, J., Vieira, I.C.G., Wilson, S.J., 2016. When is a forest a forest? Forest concepts and definitions in the era of forest and landscape restoration. *Ambio* 45, 538–550. <https://doi.org/10.1007/s13280-016-0772-y>
- Chen, J.M., Black, T.A., 1992. Defining leaf area index for non-flat leaves. *Plant Cell Environ* 15, 421–429. <https://doi.org/10.1111/j.1365-3040.1992.tb00992.x>

- Chen, J.M., Rich, P.M., Gower, S.T., Norman, J.M., Plummer, S., 1997. Leaf area index of boreal forests: Theory, techniques, and measurements. *J. Geophys. Res.* 102, 29429–29443. <https://doi.org/10.1029/97JD01107>
- Cheng, Y.-B., Zarco-Tejada, P.J., Riaño, D., Rueda, C.A., Ustin, S.L., 2006. Estimating vegetation water content with hyperspectral data for different canopy scenarios: Relationships between AVIRIS and MODIS indexes. *Remote Sensing of Environment* 105, 354–366. <https://doi.org/10.1016/j.rse.2006.07.005>
- Chianucci, F., Cutini, A., 2012. Digital hemispherical photography for estimating forest canopy properties: current controversies and opportunities. *iForest* 5, 290–295. <https://doi.org/10.3832/ifor0775-005>
- Clasen, A., Somers, B., Pipkins, K., Tits, L., Segl, K., Brell, M., Kleinschmit, B., Spengler, D., Lausch, A., Förster, M., 2015. Spectral Unmixing of Forest Crown Components at Close Range, Airborne and Simulated Sentinel-2 and EnMAP Spectral Imaging Scale. *Remote Sensing* 7, 15361–15387. <https://doi.org/10.3390/rs71115361>
- Clevers, J.G.P.W., Kooistra, L., Schaepman, M.E., 2010. Estimating canopy water content using hyperspectral remote sensing data. *International Journal of Applied Earth Observation and Geoinformation* 12, 119–125. <https://doi.org/10.1016/j.jag.2010.01.007>
- Cohen, W.B., 1991. Response of vegetation indices to changes in three measures of leaf water stress. *Photogrammetric Engineering and Remote Sensing* 57.2, 195–202.
- Corbera, E., Schroeder, H., 2011. Governing and implementing REDD+. *Environmental Science & Policy* 14, 89–99. <https://doi.org/10.1016/j.envsci.2010.11.002>
- Couteron, P., 2002. Quantifying change in patterned semi-arid vegetation by Fourier analysis of digitized aerial photographs. *International Journal of Remote Sensing* 23, 3407–3425. <https://doi.org/10.1080/01431160110107699>
- Cremer, F., Urbazaez, M., Cortes, J., Truckenbrodt, J., Schullius, C., Thiel, C., 2020. Potential of Recurrence Metrics from Sentinel-1 Time Series for Deforestation Mapping. *IEEE J. Sel. Top. Appl. Earth Observations Remote Sensing* 13, 5233–5240. <https://doi.org/10.1109/JSTARS.2020.3019333>
- Dawani, J., 2020. Hands-on mathematics for deep learning: build a solid mathematical foundation for training efficient deep neural networks. Packt Publishing, Birmingham.
- de Bem, P., de Carvalho Junior, O., Fontes Guimarães, R., Trancoso Gomes, R., 2020. Change Detection of Deforestation in the Brazilian Amazon Using Landsat Data and Convolutional Neural Networks. *Remote Sensing* 12, 901. <https://doi.org/10.3390/rs12060901>
- de Wasseige, C., Defourny, P., 2004. Remote sensing of selective logging impact for tropical forest management. *Forest Ecology and Management* 188, 161–173. <https://doi.org/10.1016/j.foreco.2003.07.035>
- Delbart, N., Kergoat, L., Le Toan, T., Lhermitte, J., Picard, G., 2005. Determination of phenological dates in boreal regions using normalized difference water index. *Remote Sensing of Environment* 97, 26–38. <https://doi.org/10.1016/j.rse.2005.03.011>
- Delbart, N., Le Toan, T., Kergoat, L., Fedotova, V., 2006. Remote sensing of spring phenology in boreal regions: A free of snow-effect method using NOAA-AVHRR and SPOT-VGT data (1982–2004). *Remote Sensing of Environment* 101, 52–62. <https://doi.org/10.1016/j.rse.2005.11.012>
- Delorme, N. (1998). Aménagement forestier en Guinée: étude de cas. CIRAD-Forêt., 1998.
- Deutscher, J., Gutjahr, K., Perko, R., Raggam, H., Hirschmugl, M., Schardt, M., 2017. Humid tropical forest monitoring with multi-temporal L-, C- and X-band SAR data, in: 2017 9th International Workshop on the Analysis of Multitemporal Remote Sensing Images (MultiTemp). Presented at the 2017 9th International Workshop on the Analysis of Multitemporal Remote Sensing Images (MultiTemp), IEEE, Brugge, Belgium, pp. 1–4. <https://doi.org/10.1109/Multi-Temp.2017.8035264>

- Deutscher, J., Perko, R., Gutjahr, K., Hirschmugl, M., Schardt, M., 2013. Mapping Tropical Rainforest Canopy Disturbances in 3D by COSMO-SkyMed Spotlight InSAR-Stereo Data to Detect Areas of Forest Degradation. *Remote Sensing* 5, 648–663. <https://doi.org/10.3390/rs5020648>
- DeVries, B., Decuyper, M., Verbesselt, J., Zeileis, A., Herold, M., Joseph, S., 2015. Tracking disturbance-regrowth dynamics in tropical forests using structural change detection and Landsat time series. *Remote Sensing of Environment* 169, 320–334. <https://doi.org/10.1016/j.rse.2015.08.020>
- Doblas, J., Shimabukuro, Y., Sant’Anna, S., Carneiro, A., Aragão, L., Almeida, C., 2020. Optimizing Near Real-Time Detection of Deforestation on Tropical Rainforests Using Sentinel-1 Data. *Remote Sensing* 12, 3922. <https://doi.org/10.3390/rs12233922>
- Duporge, I., Isupova, O., Reece, S., Macdonald, D.W., Wang, T., 2021. Using very-high-resolution satellite imagery and deep learning to detect and count African elephants in heterogeneous landscapes. *Remote Sens Ecol Conserv* 7, 369–381. <https://doi.org/10.1002/rse2.195>
- Dupuis, C., Lejeune, P., Michez, A., Fayolle, A., 2020. How Can Remote Sensing Help Monitor Tropical Moist Forest Degradation?—A Systematic Review. *Remote Sensing* 12, 1087. <https://doi.org/10.3390/rs12071087>
- Durán, S.M., Gianoli, E., 2013. Carbon stocks in tropical forests decrease with liana density. *Biol. Lett.* 9, 20130301. <https://doi.org/10.1098/rsbl.2013.0301>
- Dutrieux, L.P., Verbesselt, J., Kooistra, L., Herold, M., 2015. Monitoring forest cover loss using multiple data streams, a case study of a tropical dry forest in Bolivia. *ISPRS Journal of Photogrammetry and Remote Sensing* 107, 112–125. <https://doi.org/10.1016/j.isprsjprs.2015.03.015>
- Emek, R.A., Demir, N., 2020. Building detection from SAR images using UNet deep learning method. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.* XLIV-4/W3-2020, 215–218. <https://doi.org/10.5194/isprs-archives-XLIV-4-W3-2020-215-2020>
- Ernst, C., Verhegghen, A., Mayaux, P., Hansen, M., Defourny, P., 2010. Cartographie du couvert forestier et des changements du couvert forestier en Afrique centrale. *Les forêts du Bassin du Congo: état des forêts* 23–42.
- FAO. 2011. *State of the World’s Forests 2011*. Rome. ISBN 978-92-5-106750-5.
- FAO. 2020. *Évaluation des ressources forestières mondiales 2020 - Principaux résultats*. Rome. <https://doi.org/10.4060/ca8753f>
- Fensholt, R., Sandholt, I., 2003. Derivation of a shortwave infrared water stress index from MODIS near- and shortwave infrared data in a semiarid environment. *Remote Sensing of Environment* 87, 111–121. <https://doi.org/10.1016/j.rse.2003.07.002>
- Feranec, J. (Ed.), 2016. *European landscape dynamics: CORINE land cover data*. CRC Press, Boca Raton, FL.
- Flint, E.P., Richards, J.F., 1994. Trends in Carbon Content of Vegetation in South and Southeast Asia Associated with Changes in Land Use, in: Dale, V.H. (Ed.), *Effects of Land-Use Change on Atmospheric CO<sub>2</sub> Concentrations*, Ecological Studies. Springer New York, New York, NY, pp. 201–299. [https://doi.org/10.1007/978-1-4613-8363-5\\_6](https://doi.org/10.1007/978-1-4613-8363-5_6)
- Fukushima, K., 1980. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biol. Cybernetics* 36, 193–202. <https://doi.org/10.1007/BF00344251>
- Gao, Y., Skutsch, M., Paneque-Gálvez, J., Ghilardi, A., 2020. Remote sensing of forest degradation: a review. *Environ. Res. Lett.* 15, 103001. <https://doi.org/10.1088/1748-9326/abaad7>
- Garrigues, S., Shabanov, N.V., Swanson, K., Morisette, J.T., Baret, F., Myneni, R.B., 2008. Intercomparison and sensitivity analysis of Leaf Area Index retrievals from LAI-2000,

- AccuPAR, and digital hemispherical photography over croplands. *Agricultural and Forest Meteorology* 148, 1193–1209. <https://doi.org/10.1016/j.agrformet.2008.02.014>
- Gaston, G., Brown, S., Lorenzini, M., Singh, K.D., 1998. State and change in carbon pools in the forests of tropical Africa. *Global Change Biology* 4, 97–114. <https://doi.org/10.1046/j.1365-2486.1998.00114.x>
- Ghazoul, J., Burivalova, Z., Garcia-Ulloa, J., King, L.A., 2015. Conceptualizing Forest Degradation. *Trends in Ecology & Evolution* 30, 622–632. <https://doi.org/10.1016/j.tree.2015.08.001>
- Giambelluca, T.W., Ziegler, A.D., Nullet, M.A., Truong, D.M., Tran, L.T., 2003. Transpiration in a small tropical forest patch. *Agricultural and Forest Meteorology* 117, 1–22. [https://doi.org/10.1016/S0168-1923\(03\)00041-8](https://doi.org/10.1016/S0168-1923(03)00041-8)
- Goldberg, T.L., Gillespie, T.R., Rwego, I.B., Estoff, E.L., Chapman, C.A., 2008. Forest Fragmentation as Cause of Bacterial Transmission among Nonhuman Primates, Humans, and Livestock, Uganda. *Emerg. Infect. Dis.* 14, 1375–1382. <https://doi.org/10.3201/eid1409.071196>
- Gonsamo, A., Pellikka, P., 2009. The computation of foliage clumping index using hemispherical photography. *Agricultural and Forest Meteorology* 149, 1781–1787. <https://doi.org/10.1016/j.agrformet.2009.06.001>
- Govender, M., Govender, P., Weiersbye, I., Witkowski, E., Ahmed, F., 2009. Review of commonly used remote sensing and ground-based technologies to measure plant water stress. *Water SA* 35. <https://doi.org/10.4314/wsa.v35i5.49201>
- Hamdi, Z.M., Brandmeier, M., Straub, C., 2019. Forest Damage Assessment Using Deep Learning on High Resolution Remote Sensing Data. *Remote Sensing* 11, 1976. <https://doi.org/10.3390/rs11171976>
- Han, M., Zhu, X., Yao, W., 2012. Remote sensing image classification based on neural network ensemble algorithm. *Neurocomputing* 78, 133–138. <https://doi.org/10.1016/j.neucom.2011.04.044>
- Hansen, M.C., Potapov, P.V., Moore, R., Hancher, M., Turubanova, S.A., Tyukavina, A., Thau, D., Stehman, S.V., Goetz, S.J., Loveland, T.R., Kommareddy, A., Egorov, A., Chini, L., Justice, C.O., Townshend, J.R.G., 2013. High-Resolution Global Maps of 21st-Century Forest Cover Change. *Science* 342, 850–853. <https://doi.org/10.1126/science.1244693>
- Hasanah, A., Supriatna, Indrawan, M., 2020. Assessment of tropical forest degradation on a small island using the enhanced vegetation index. *IOP Conf. Ser.: Earth Environ. Sci.* 481, 012061. <https://doi.org/10.1088/1755-1315/481/1/012061>
- He, K., Zhang, X., Ren, S., Sun, J., 2015. Deep Residual Learning for Image Recognition. <https://doi.org/10.48550/ARXIV.1512.03385>
- Hirschmugl, M., Deutscher, J., Sobe, C., Bouvet, A., Mermoz, S., Schardt, M., 2020. Use of SAR and Optical Time Series for Tropical Forest Disturbance Mapping. *Remote Sensing* 12, 727. <https://doi.org/10.3390/rs12040727>
- Hirschmugl, M., Steinegger, M., Gallaun, H., Schardt, M., 2014. Mapping Forest Degradation due to Selective Logging by Means of Time Series Analysis: Case Studies in Central Africa. *Remote Sensing* 6, 756–775. <https://doi.org/10.3390/rs6010756>
- Houghton, R.A., 2007. Balancing the Global Carbon Budget. *Annu. Rev. Earth Planet. Sci.* 35, 313–347. <https://doi.org/10.1146/annurev.earth.35.031306.140057>
- Houghton, R.A., 2005. Aboveground Forest Biomass and the Global Carbon Balance. *Global Change Biology* 11, 945–958. <https://doi.org/10.1111/j.1365-2486.2005.00955.x>
- Houghton, R.A., 1990. The global effects of tropical deforestation. *Environ. Sci. Technol.* 24, 414–422. <https://doi.org/10.1021/es00074a001>
- Houghton, R.A., Hackler, J.L., 1999. Emissions of carbon from forestry and land-use change in tropical Asia. *Global Change Biology* 5, 481–492. <https://doi.org/10.1046/j.1365-2486.1999.00244.x>



- Hua, Y., Marcos, D., Mou, L., Zhu, X.X., Tuia, D., 2022. Semantic Segmentation of Remote Sensing Images With Sparse Annotations. *IEEE Geosci. Remote Sensing Lett.* 19, 1–5. <https://doi.org/10.1109/LGRS.2021.3051053>
- Huang, S., Tang, L., Hupy, J.P., Wang, Y., Shao, G., 2021. A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. *J. For. Res.* 32, 1–6. <https://doi.org/10.1007/s11676-020-01155-1>
- Huete, A., Didan, K., Miura, T., Rodriguez, E.P., Gao, X., Ferreira, L.G., 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment* 83, 195–213. [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2)
- Huete, A.R., 1988. A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment* 25, 295–309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Hunt Jr, E.R., Rock, B.N., 1989. Detection of changes in leaf water content using near-and middle-infrared reflectances. *Remote sensing of environment* 30.1, 43–54.
- IPCC, 2007: Climate Change 2007: Synthesis Report. Contribution of Working Groups I, II and III to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, Pachauri, R.K and Reisinger, A. (eds.)]. IPCC, Geneva, Switzerland, 104 pp., 2007.
- Irvin, J., Sheng, H., Ramachandran, N., Johnson-Yu, S., Zhou, S., Story, K., Rustowicz, R., Elsworth, C., Austin, K., Ng, A.Y., 2020. ForestNet: Classifying Drivers of Deforestation in Indonesia using Deep Learning on Satellite Imagery. arXiv:2011.05479 [cs, eess].
- ITTO guidelines for the restoration, management and rehabilitation of degraded and secondary tropical forests, 2002. , ITTO policy development series. International Tropical Timber Organization, Yokohama.
- Iverson, L.R., Brown, S., Prasad, A., Mitasova, H., Gillespie, A.J.R., Lugo, A.E., 1994. Use of GIS for Estimating Potential and Actual Forest Biomass for Continental South and Southeast Asia, in: Dale, V.H. (Ed.), *Effects of Land-Use Change on Atmospheric CO2 Concentrations, Ecological Studies*. Springer New York, New York, NY, pp. 67–116. [https://doi.org/10.1007/978-1-4613-8363-5\\_3](https://doi.org/10.1007/978-1-4613-8363-5_3)
- Jaffrain, G., Leroux, A., Vo Quang, A., Pinet, C., Dessagboli, B., Gauthier, Y., Moiret, A., 2021. Suivi de la dynamique de l'occupation du sol en République de Guinée par imagerie satellitaire Spot: Transfert technologique pour le développement d'outils performants d'aide à la décision. *RFPT* 223, 59–80. <https://doi.org/10.52638/rfpt.2021.563>
- Jordan, C.F., 1969. Derivation of Leaf-Area Index from Quality of Light on the Forest Floor. *Ecology* 50, 663–666. <https://doi.org/10.2307/1936256>
- Joshi, N., Mitchard, E.T., Woo, N., Torres, J., Moll-Rocek, J., Ehammer, A., Collins, M., Jepsen, M.R., Fensholt, R., 2015. Mapping dynamics of deforestation and forest degradation in tropical forests using radar satellite data. *Environmental Research Letters* 10, 034014. <https://doi.org/10.1088/1748-9326/10/3/034014>
- Kapos, V., 1989. Effects of isolation on the water status of forest patches in the Brazilian Amazon. *J. Trop. Ecol.* 5, 173–185. <https://doi.org/10.1017/S0266467400003448>
- Kaptue Tchuente, A.T., Roujean, J.-L., Faroux, S., 2010. ECOCLIMAP-II: An ecosystem classification and land surface parameters database of Western Africa at 1km resolution for the African Monsoon Multidisciplinary Analysis (AMMA) project. *Remote Sensing of Environment* 114, 961–976. <https://doi.org/10.1016/j.rse.2009.12.008>
- Knopp, L., Wieland, M., Rättich, M., Martinis, S., 2020. A Deep Learning Approach for Burned Area Segmentation with Sentinel-2 Data. *Remote Sensing* 12, 2422. <https://doi.org/10.3390/rs12152422>
- Kobayashi, H., Delbart, N., Suzuki, R., Kushida, K., 2010. A satellite-based method for monitoring seasonality in the overstory leaf area index of Siberian larch forest. *J. Geophys. Res.* 115, G01002. <https://doi.org/10.1029/2009JG000939>

- Koubouana, F., Ifo, S.A., Ndzai, S.F., Stoffenne, B., Mondzali-Lénguya, R., 2018. Étude Comparative D'Une Forêt Primaire Et D'Une Forêt Dégradée Au Nord De La République Du Congo Par Référence À La Structure Des Forêts Tropicales Humides. <https://doi.org/10.5281/ZENODO.1436597>
- Kowalski, K., Okujeni, A., Brell, M., Hostert, P., 2022. Quantifying drought effects in Central European grasslands through regression-based unmixing of intra-annual Sentinel-2 time series. *Remote Sensing of Environment* 268, 112781. <https://doi.org/10.1016/j.rse.2021.112781>
- Kuck, T.N., Sano, E.E., Bispo, P. da C., Shiguemori, E.H., Silva Filho, P.F.F., Matricardi, E.A.T., 2021. A Comparative Assessment of Machine-Learning Techniques for Forest Degradation Caused by Selective Logging in an Amazon Region Using Multitemporal X-Band SAR Images. *Remote Sensing* 13, 3341. <https://doi.org/10.3390/rs13173341>
- Kunert, N., Aparecido, L.M.T., Higuchi, N., Santos, J. dos, Trumbore, S., 2015. Higher tree transpiration due to road-associated edge effects in a tropical moist lowland forest. *Agricultural and Forest Meteorology* 213, 183–192. <https://doi.org/10.1016/j.agrformet.2015.06.009>
- Lambers, K., Verschoof-van der Vaart, W., Bourgeois, Q., 2019. Integrating Remote Sensing, Machine Learning, and Citizen Science in Dutch Archaeological Prospection. *Remote Sensing* 11, 794. <https://doi.org/10.3390/rs11070794>
- Laurance, W.F., Ferreira, L.V., Rankin-de Merona, J.M., Laurance, S.G., 1998. Rainforest fragmentation and the dynamics of Amazonian tree communities. *Ecology* 79, 2032–2040. [https://doi.org/10.1890/0012-9658\(1998\)079\[2032:RFFATD\]2.0.CO;2](https://doi.org/10.1890/0012-9658(1998)079[2032:RFFATD]2.0.CO;2)
- Le Toan, T., Quegan, S., Woodward, I., Lomas, M., Delbart, N., Picard, G., 2004. Relating Radar Remote Sensing of Biomass to Modelling of Forest Carbon Budgets. *Climatic Change* 67, 379–402. <https://doi.org/10.1007/s10584-004-3155-5>
- Lee, S.-H., Han, K.-J., Lee, K., Lee, K.-J., Oh, K.-Y., Lee, M.-J., 2020. Classification of Landscape Affected by Deforestation Using High-Resolution Remote Sensing Data and Deep-Learning Techniques. *Remote Sensing* 12, 3372. <https://doi.org/10.3390/rs12203372>
- Lewis, S.L., 2006. Tropical forests and the changing earth system. *Philosophical Transactions of the Royal Society B: Biological Sciences* 361, 195–210. <https://doi.org/10.1098/rstb.2005.1711>
- Lewis, S.L., Lopez-Gonzalez, G., Sonké, B., Affum-Baffoe, K., Baker, T.R., Ojo, L.O., Phillips, O.L., Reitsma, J.M., White, L., Comiskey, J.A., K, M.-N.D., Ewango, C.E.N., Feldpausch, T.R., Hamilton, A.C., Gloor, M., Hart, T., Hladik, A., Lloyd, J., Lovett, J.C., Makana, J.-R., Malhi, Y., Mbago, F.M., Ndangalasi, H.J., Peacock, J., Peh, K.S.-H., Sheil, D., Sunderland, T., Swaine, M.D., Taplin, J., Taylor, D., Thomas, S.C., Votere, R., Wöll, H., 2009. Increasing carbon storage in intact African tropical forests. *Nature* 457, 1003–1006. <https://doi.org/10.1038/nature07771>
- Lima, T.A., Beuchle, R., Langner, A., Grecchi, R.C., Griess, V.C., Achard, F., 2019. Comparing Sentinel-2 MSI and Landsat 8 OLI Imagery for Monitoring Selective Logging in the Brazilian Amazon. *Remote Sensing* 11, 961. <https://doi.org/10.3390/rs11080961>
- Liu, J., Pattey, E., 2010. Retrieval of leaf area index from top-of-canopy digital photography over agricultural crops. *Agricultural and Forest Meteorology* 150, 1485–1490. <https://doi.org/10.1016/j.agrformet.2010.08.002>
- Lu, D., 2005. Aboveground biomass estimation using Landsat TM data in the Brazilian Amazon. *International Journal of Remote Sensing* 26, 2509–2525. <https://doi.org/10.1080/01431160500142145>
- Lu, D., Batistella, M., 2005. Exploring TM image texture and its relationships with biomass estimation in Rondônia, Brazilian Amazon. *Acta Amaz.* 35, 249–257. <https://doi.org/10.1590/S0044-59672005000200015>

- Lucas, R., Armston, J., Fairfax, R., Fensham, R., Accad, A., Carreiras, J., Kelley, J., Bunting, P., Clewley, D., Bray, S., Metcalfe, D., Dwyer, J., Bowen, M., Eyre, T., Laidlaw, M., Shimada, M., 2010. An Evaluation of the ALOS PALSAR L-Band Backscatter—Above Ground Biomass Relationship Queensland, Australia: Impacts of Surface Moisture Condition and Vegetation Structure. *IEEE J. Sel. Top. Appl. Earth Observations Remote Sensing* 3, 576–593. <https://doi.org/10.1109/JSTARS.2010.2086436>
- Malhi, Y., Grace, J., 2000. Tropical forests and atmospheric carbon dioxide. *Trends in Ecology & Evolution* 15, 332–337. [https://doi.org/10.1016/S0169-5347\(00\)01906-6](https://doi.org/10.1016/S0169-5347(00)01906-6)
- Marengo, J.A., Souza, C.M., Thonicke, K., Burton, C., Halladay, K., Betts, R.A., Alves, L.M., Soares, W.R., 2018. Changes in Climate and Land Use Over the Amazon Region: Current and Future Variability and Trends. *Front. Earth Sci.* 6, 228. <https://doi.org/10.3389/feart.2018.00228>
- Maretto, R.V., Fonseca, L.M.G., Jacobs, N., Korting, T.S., Bendini, H.N., Parente, L.L., 2021. Spatio-Temporal Deep Learning Approach to Map Deforestation in Amazon Rainforest. *IEEE Geosci. Remote Sensing Lett.* 18, 771–775. <https://doi.org/10.1109/LGRS.2020.2986407>
- Masolele, R.N., De Sy, V., Herold, M., Marcos, D., Verbesselt, J., Gieseke, F., Mullissa, A.G., Martius, C., 2021. Spatial and temporal deep learning methods for deriving land-use following deforestation: A pan-tropical case study using Landsat time series. *Remote Sensing of Environment* 264, 112600. <https://doi.org/10.1016/j.rse.2021.112600>
- Matricardi, E.A.T., Skole, D.L., Costa, O.B., Pedlowski, M.A., Samek, J.H., Miguel, E.P., 2020. Long-term forest degradation surpasses deforestation in the Brazilian Amazon. *Science* 369, 1378–1382. <https://doi.org/10.1126/science.abb3021>
- Maxwell, S.L., Evans, T., Watson, J.E.M., Morel, A., Grantham, H., Duncan, A., Harris, N., Potapov, P., Runting, R.K., Venter, O., Wang, S., Malhi, Y., 2019. Degradation and forgone removals increase the carbon impact of intact forest loss by 626%. *Sci. Adv.* 5, eaax2546. <https://doi.org/10.1126/sciadv.aax2546>
- Mayaux, P., Achard, F., Malingreau, J.-P., 1998. Global tropical forest area measurements derived from coarse resolution satellite imagery: a comparison with other approaches. *Envir. Conserv.* 25, 37–52. <https://doi.org/10.1017/S0376892998000083>
- Mermoz, S., Le Toan, T., 2016. Forest Disturbances and Regrowth Assessment Using ALOS PALSAR Data from 2007 to 2010 in Vietnam, Cambodia and Lao PDR. *Remote Sensing* 8, 217. <https://doi.org/10.3390/rs8030217>
- Mette, T., Papathanassiou, K.P., Hajnsek, I., Zimmermann, R., 2002. Forest biomass estimation using polarimetric SAR interferometry. *IEEE*, pp. 817–819. <https://doi.org/10.1109/IGARSS.2002.1025695>
- Milletari, F., Navab, N., Ahmadi, S.-A., 2016. V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation, in: 2016 Fourth International Conference on 3D Vision (3DV). Presented at the 2016 Fourth International Conference on 3D Vision (3DV), IEEE, Stanford, CA, USA, pp. 565–571. <https://doi.org/10.1109/3DV.2016.79>
- Mitchard, E.T.A., Saatchi, S.S., Woodhouse, I.H., Nangendo, G., Ribeiro, N.S., Williams, M., Ryan, C.M., Lewis, S.L., Feldpausch, T.R., Meir, P., 2009. Using satellite radar backscatter to predict above-ground woody biomass: A consistent relationship across four different African landscapes. *Geophys. Res. Lett.* 36, L23401. <https://doi.org/10.1029/2009GL040692>
- Montesano, P.M., Cook, B.D., Sun, G., Simard, M., Nelson, R.F., Ranson, K.J., Zhang, Z., Luthcke, S., 2013. Achieving accuracy requirements for forest biomass mapping: A spaceborne data fusion method for estimating forest biomass and LiDAR sampling error. *Remote Sensing of Environment* 130, 153–170. <https://doi.org/10.1016/j.rse.2012.11.016>

- Morales-Barquero, L., Skutsch, M., Jardel-Peláez, E., Ghilardi, A., Kleinn, C., Healey, J., 2014. Operationalizing the Definition of Forest Degradation for REDD+, with Application to Mexico. *Forests* 5, 1653–1681. <https://doi.org/10.3390/f5071653>
- Morton, D.C., DeFries, R.S., Nagol, J., Souza, C.M., Kasischke, E.S., Hurtt, G.C., Dubayah, R., 2011. Mapping canopy damage from understory fires in Amazon forests using annual time series of Landsat and MODIS data. *Remote Sensing of Environment* 115, 1706–1720. <https://doi.org/10.1016/j.rse.2011.03.002>
- Mylona, E., Daskalopoulou, V., Sykioti, O., Koutroumbas, K., Rontogiannis, A., 2018. Classification of Sentinel-2 Images Utilizing Abundance Representation. *Proceedings* 2, 328. <https://doi.org/10.3390/ecrs-2-05141>
- Nepstad, D.C., Verssimo, A., Alencar, A., Nobre, C., Lima, E., Lefebvre, P., Schlesinger, P., Potter, C., Moutinho, P., Mendoza, E., Cochrane, M., Brooks, V., 1999. Large-scale impoverishment of Amazonian forests by logging and fire. *Nature* 398, 505–508. <https://doi.org/10.1038/19066>
- Numata, I., Khand, K., Kjaersgaard, J., Cochrane, M.A., Silva, S.S., 2021. Forest evapotranspiration dynamics over a fragmented forest landscape under drought in southwestern Amazonia. *Agricultural and Forest Meteorology* 306, 108446. <https://doi.org/10.1016/j.agrformet.2021.108446>
- Olivero, J., Fa, J.E., Real, R., Márquez, A.L., Farfán, M.A., Vargas, J.M., Gaveau, D., Salim, M.A., Park, D., Suter, J., King, S., Leendertz, S.A., Sheil, D., Nasi, R., 2017. Recent loss of closed forests is associated with Ebola virus disease outbreaks. *Sci Rep* 7, 14291. <https://doi.org/10.1038/s41598-017-14727-9>
- Olofsson, P., Foody, G.M., Herold, M., Stehman, S.V., Woodcock, C.E., Wulder, M.A., 2014. Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment* 148, 42–57. <https://doi.org/10.1016/j.rse.2014.02.015>
- Olofsson, P., Foody, G.M., Stehman, S.V., Woodcock, C.E., 2013. Making better use of accuracy data in land change studies: Estimating accuracy and area and quantifying uncertainty using stratified estimation. *Remote Sensing of Environment* 129, 122–131. <https://doi.org/10.1016/j.rse.2012.10.031>
- Olofsson, P., Stehman, S.V., Woodcock, C.E., Sulla-Menashe, D., Sibley, A.M., Newell, J.D., Friedl, M.A., Herold, M., 2012. A global land-cover validation data set, part I: fundamental design principles. *International Journal of Remote Sensing* 33, 5768–5788. <https://doi.org/10.1080/01431161.2012.674230>
- Ortega Adarme, M., Queiroz Feitosa, R., Nigri Happ, P., Aparecido De Almeida, C., Rodrigues Gomes, A., 2020. Evaluation of Deep Learning Techniques for Deforestation Detection in the Brazilian Amazon and Cerrado Biomes From Remote Sensing Imagery. *Remote Sensing* 12, 910. <https://doi.org/10.3390/rs12060910>
- Park, S.W., Lee, Y.W., 2019. Detection of forest disaster using high-resolution satellite images with semantic segmentation, in: Bruzzone, L., Bovolo, F., Benediktsson, J.A. (Eds.), *Image and Signal Processing for Remote Sensing XXV*. Presented at the Image and Signal Processing for Remote Sensing XXV, SPIE, Strasbourg, France, p. 59. <https://doi.org/10.1117/12.2532990>
- Pearson, T.R.H., Brown, S., Murray, L., Sidman, G., 2017. Greenhouse gas emissions from tropical forest degradation: an underestimated source. *Carbon Balance Manage* 12, 3. <https://doi.org/10.1186/s13021-017-0072-2>
- Pelletier, C., Valero, S., Inglada, J., Champion, N., Dedieu, G., 2016. Assessing the robustness of Random Forests to map land cover with high resolution satellite image time series over large areas. *Remote Sensing of Environment* 187, 156–168. <https://doi.org/10.1016/j.rse.2016.10.010>

- Pérez-Salicrup, D.R., Barker, M.G., 2000. Effect of liana cutting on water potential and growth of adult *Senna multijuga* (Caesalpinioideae) trees in a Bolivian tropical forest. *Oecologia* 124, 469–475. <https://doi.org/10.1007/PL00008872>
- Pérez-Salicrup, D.R., De Meijere, W., 2005. Number of Lianas per Tree and Number of Trees Climbed by Lianas at Los Tuxtlas, Mexico: Short Communications. *Biotropica* 37, 153–156. <https://doi.org/10.1111/j.1744-7429.2005.03223.x>
- Perez-Salicrup, D.R., Sork, V.L., Putz, F.E., 2001. Lianas and Trees in a Liana Forest of Amazonian Bolivia. *Biotropica* 33, 34–47. <https://doi.org/10.1111/j.1744-7429.2001.tb00155.x>
- Pettorelli, N., Vik, J.O., Mysterud, A., Gaillard, J.-M., Tucker, C.J., Stenseth, N.Ch., 2005. Using the satellite-derived NDVI to assess ecological responses to environmental change. *Trends in Ecology & Evolution* 20, 503–510. <https://doi.org/10.1016/j.tree.2005.05.011>
- Phillips, O.L., Vásquez Martínez, R., Arroyo, L., Baker, T.R., Killeen, T., Lewis, S.L., Malhi, Y., Monteagudo Mendoza, A., Neill, D., Núñez Vargas, P., Alexiades, M., Cerón, C., Di Fiore, A., Erwin, T., Jardim, A., Palacios, W., Saldias, M., Vinceti, B., 2002. Increasing dominance of large lianas in Amazonian forests. *Nature* 418, 770–774. <https://doi.org/10.1038/nature00926>
- Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V., Murayama, Y., Ranagalage, M., 2020. Sentinel-2 Data for Land Cover/Use Mapping: A Review. *Remote Sensing* 12, 2291. <https://doi.org/10.3390/rs12142291>
- Ploton, P., Barbier, N., Coutron, P., Antin, C.M., Ayyappan, N., Balachandran, N., Barathan, N., Bastin, J.-F., Chuyong, G., Dauby, G., Droissart, V., Gastellu-Etchegorry, J.-P., Kamdem, N.G., Kenfack, D., Libalah, M., Mofack, G., Momo, S.T., Pargal, S., Petronelli, P., Proisy, C., Réjou-Méchain, M., Sonké, B., Texier, N., Thomas, D., Verley, P., Zebaze Dongmo, D., Berger, U., Pélissier, R., 2017. Toward a general tropical forest biomass prediction model from very high resolution optical satellite images. *Remote Sensing of Environment* 200, 140–153. <https://doi.org/10.1016/j.rse.2017.08.001>
- Putz, F.E., 1983. Liana Biomass and Leaf Area of a “Tierra Firme” Forest in the Rio Negro Basin, Venezuela. *Biotropica* 15, 185. <https://doi.org/10.2307/2387827>
- Putz, F.E., Redford, K.H., 2010. The Importance of Defining ‘Forest’: Tropical Forest Degradation, Deforestation, Long-term Phase Shifts, and Further Transitions: Importance of Defining ‘Forest.’ *Biotropica* 42, 10–20. <https://doi.org/10.1111/j.1744-7429.2009.00567.x>
- Qayyum, A., Anwar, S.M., Awais, M., Majid, M., 2017. Medical image retrieval using deep convolutional neural network. *Neurocomputing* 266, 8–20. <https://doi.org/10.1016/j.neucom.2017.05.025>
- Qin, Y., Xiao, X., Wigneron, J.-P., Ciais, P., Brandt, M., Fan, L., Li, X., Crowell, S., Wu, X., Doughty, R., Zhang, Y., Liu, F., Sitch, S., Moore, B., 2021. Carbon loss from forest degradation exceeds that from deforestation in the Brazilian Amazon. *Nat. Clim. Chang.* 11, 442–448. <https://doi.org/10.1038/s41558-021-01026-5>
- Ramírez-Cuesta, J.M., Minacapilli, M., Motisi, A., Consoli, S., Intrigliolo, D.S., Vanella, D., 2021. Characterization of the main land processes occurring in Europe (2000-2018) through a MODIS NDVI seasonal parameter-based procedure. *Science of The Total Environment* 799, 149346. <https://doi.org/10.1016/j.scitotenv.2021.149346>
- Reiche, J., Hamunyela, E., Verbesselt, J., Hoekman, D., Herold, M., 2018. Improving near-real time deforestation monitoring in tropical dry forests by combining dense Sentinel-1 time series with Landsat and ALOS-2 PALSAR-2. *Remote Sensing of Environment* 204, 147–161. <https://doi.org/10.1016/j.rse.2017.10.034>
- Reiche, J., Souza, C.M., Hoekman, D.H., Verbesselt, J., Persaud, H., Herold, M., 2013. Feature Level Fusion of Multi-Temporal ALOS PALSAR and Landsat Data for Mapping and Monitoring of Tropical Deforestation and Forest Degradation. *IEEE Journal of Selected*

- Topics in Applied Earth Observations and Remote Sensing 6, 2159–2173. <https://doi.org/10.1109/JSTARS.2013.2245101>
- Reiche, J., Verbesselt, J., Hoekman, D., Herold, M., 2015. Fusing Landsat and SAR time series to detect deforestation in the tropics. *Remote Sensing of Environment* 156, 276–293. <https://doi.org/10.1016/j.rse.2014.10.001>
- Richardson, A.J., Wiegand, C.L., 1977. Distinguishing Vegetation from Soil Background Information. *Photogrammetric engineering and remote sensing* 43, 1541–1552.
- Roberts, D.A., Gardner, M., Church, R., Ustin, S., Scheer, G., Green, R.O., 1998. Mapping Chaparral in the Santa Monica Mountains Using Multiple Endmember Spectral Mixture Models. *Remote Sensing of Environment* 65, 267–279. [https://doi.org/10.1016/S0034-4257\(98\)00037-6](https://doi.org/10.1016/S0034-4257(98)00037-6)
- Ronneberger, O., Fischer, P., Brox, T., 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation, in: Navab, N., Hornegger, J., Wells, W.M., Frangi, A.F. (Eds.), *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. Springer International Publishing, Cham, pp. 234–241. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)
- Rouse, J.W., Jr., Haas, R.H., Schell, J.A., Deering, D.W., 1974. Monitoring Vegetation Systems in the Great Plains with Erts. *NASA Special Publication* 351, 309.
- Rulli, M.C., D’Odorico, P., Galli, N., Hayman, D.T.S., 2021. Land-use change and the livestock revolution increase the risk of zoonotic coronavirus transmission from rhinolophid bats. *Nat Food* 2, 409–416. <https://doi.org/10.1038/s43016-021-00285-x>
- Rulli, M.C., Santini, M., Hayman, D.T.S., D’Odorico, P., 2017. The nexus between forest fragmentation in Africa and Ebola virus disease outbreaks. *Sci Rep* 7, 41613. <https://doi.org/10.1038/srep41613>
- Rundo, L., Militello, C., Russo, G., Garufi, A., Vitabile, S., Gilardi, M., Mauri, G., 2017. Automated Prostate Gland Segmentation Based on an Unsupervised Fuzzy C-Means Clustering Technique Using Multispectral T1w and T2w MR Imaging. *Information* 8, 49. <https://doi.org/10.3390/info8020049>
- Ryan, C.M., Berry, N.J., Joshi, N., 2014. Quantifying the causes of deforestation and degradation and creating transparent REDD+ baselines: A method and case study from central Mozambique. *Applied Geography* 53, 45–54. <https://doi.org/10.1016/j.apgeog.2014.05.014>
- Ryan, C.M., Hill, T., Woollen, E., Ghee, C., Mitchard, E., Cassells, G., Grace, J., Woodhouse, I.H., Williams, M., 2012. Quantifying small-scale deforestation and forest degradation in African woodlands using radar imagery. *Global Change Biology* 18, 243–257. <https://doi.org/10.1111/j.1365-2486.2011.02551.x>
- Saatchi, S., Agosti, D., Alger, K., Delabie, J., Musinsky, J., 2001. Examining Fragmentation and Loss of Primary Forest in the Southern Bahian Atlantic Forest of Brazil with Radar Imagery. *Conservation Biology* 15, 867–875. <https://doi.org/10.1046/j.1523-1739.2001.015004867.x>
- Saatchi, S.S., Soares, J.V., Alves, D.S., 1997. Mapping deforestation and land use in amazon rainforest by using SIR-C imagery. *Remote Sensing of Environment* 59, 191–202. [https://doi.org/10.1016/S0034-4257\(96\)00153-8](https://doi.org/10.1016/S0034-4257(96)00153-8)
- Safonova, A., Tabik, S., Alcaraz-Segura, D., Rubtsov, A., Maglinets, Y., Herrera, F., 2019. Detection of Fir Trees (*Abies sibirica*) Damaged by the Bark Beetle in Unmanned Aerial Vehicle Images with Deep Learning. *Remote Sensing* 11, 643. <https://doi.org/10.3390/rs11060643>
- Sánchez-Azofeifa, G.A., Castro, K., Wright, S.J., Gamon, J., Kalacska, M., Rivard, B., Schnitzer, S.A., Feng, J.L., 2009. Differences in leaf traits, leaf internal structure, and spectral reflectance between two communities of lianas and trees: Implications for remote sensing

- in tropical environments. *Remote Sensing of Environment* 113, 2076–2088. <https://doi.org/10.1016/j.rse.2009.05.013>
- Santini, M., 2021. The land use–food–coronavirus nexus. *Nat Food* 2, 390–391. <https://doi.org/10.1038/s43016-021-00290-0>
- Sasaki, N., Putz, F.E., 2009. Critical need for new definitions of “forest” and “forest degradation” in global climate change agreements. *Conservation Letters* 2, 226–232. <https://doi.org/10.1111/j.1755-263X.2009.00067.x>
- Schnitzer, S., 2002. The ecology of lianas and their role in forests. *Trends in Ecology & Evolution* 17, 223–230. [https://doi.org/10.1016/S0169-5347\(02\)02491-6](https://doi.org/10.1016/S0169-5347(02)02491-6)
- Schnitzer, S.A., Carson, W.P., 2010. Lianas suppress tree regeneration and diversity in treefall gaps: Lianas suppress tree diversity. *Ecology Letters* 13, 849–857. <https://doi.org/10.1111/j.1461-0248.2010.01480.x>
- Schnitzer, S.A., Kuzee, M.E., Bongers, F., 2005. Disentangling above- and below-ground competition between lianas and trees in a tropical forest: *Disentangling above- and below-ground competition*. *Journal of Ecology* 93, 1115–1125. <https://doi.org/10.1111/j.1365-2745.2005.01056.x>
- Schnitzer, S.A., Mangan, S.A., Dalling, J.W., Baldeck, C.A., Hubbell, S.P., Ledo, A., Muller-Landau, H., Tobin, M.F., Aguilar, S., Brassfield, D., Hernandez, A., Lao, S., Perez, R., Valdes, O., Yorke, S.R., 2012. Liana Abundance, Diversity, and Distribution on Barro Colorado Island, Panama. *PLoS ONE* 7, e52114. <https://doi.org/10.1371/journal.pone.0052114>
- Shimabukuro, Y.E., Beuchle, R., Grecchi, R.C., Achard, F., 2014. Assessment of forest degradation in Brazilian Amazon due to selective logging and fires using time series of fraction images derived from Landsat ETM+ images. *Remote Sensing Letters* 5, 773–782. <https://doi.org/10.1080/2150704X.2014.967880>
- Shimada, M., Itoh, T., Motooka, T., Watanabe, M., Shiraiishi, T., Thapa, R., Lucas, R., 2014. New global forest/non-forest maps from ALOS PALSAR data (2007–2010). *Remote Sensing of Environment* 155, 13–31. <https://doi.org/10.1016/j.rse.2014.04.014>
- Skole, D., Tucker, C., 1993. Tropical Deforestation and Habitat Fragmentation in the Amazon: Satellite Data from 1978 to 1988. *Science* 260, 1905–1910. <https://doi.org/10.1126/science.260.5116.1905>
- Somers, B., Asner, G.P., 2013. Multi-temporal hyperspectral mixture analysis and feature selection for invasive species mapping in rainforests. *Remote Sensing of Environment* 136, 14–27. <https://doi.org/10.1016/j.rse.2013.04.006>
- Somers, B., Asner, G.P., Tits, L., Coppin, P., 2011. Endmember variability in Spectral Mixture Analysis: A review. *Remote Sensing of Environment* 115, 1603–1616. <https://doi.org/10.1016/j.rse.2011.03.003>
- Souza, C., 2003. Mapping forest degradation in the Eastern Amazon from SPOT 4 through spectral mixture models. *Remote Sensing of Environment* 87, 494–506. <https://doi.org/10.1016/j.rse.2002.08.002>
- Souza, C.M., Roberts, D.A., Cochrane, M.A., 2005. Combining spectral and spatial information to map canopy damage from selective logging and forest fires. *Remote Sensing of Environment* 98, 329–343. <https://doi.org/10.1016/j.rse.2005.07.013>
- Souza, Jr, C., Siqueira, J., Sales, M., Fonseca, A., Ribeiro, J., Numata, I., Cochrane, M., Barber, C., Roberts, D., Barlow, J., 2013. Ten-Year Landsat Classification of Deforestation and Forest Degradation in the Brazilian Amazon. *Remote Sensing* 5, 5493–5513. <https://doi.org/10.3390/rs5115493>
- Sow, M., 2003. Pratiques culturelles et conservation de la biodiversité en Guinée. *ere*. <https://doi.org/10.4000/ere.5324>

- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R., 2014. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research* 15, 1929–1958.
- State of the world's forests, 2011, 2011. . Food and Agriculture Organization of the United Nations, Rome.
- Stehman, S.V., 2009. Sampling designs for accuracy assessment of land cover. *International Journal of Remote Sensing* 30, 5243–5272. <https://doi.org/10.1080/01431160903131000>
- Stoian, A., Poulain, V., Inglada, J., Poughon, V., Derksen, D., 2019. Land Cover Maps Production with High Resolution Satellite Image Time Series and Convolutional Neural Networks: Adaptations and Limits for Operational Systems. *Remote Sensing* 11, 1986. <https://doi.org/10.3390/rs11171986>
- Szantoi, Z., Jaffrain, G., Gallaun, H., Bielski, C., Ruf, K., Lupi, A., Miletich, P., Giroux, A.-C., Carlan, I., Croi, W., Augu, H., Kowalewski, C., Brink, A., 2021. Quality assurance and assessment framework for land cover maps validation in the Copernicus Hot Spot Monitoring activity. *European Journal of Remote Sensing* 54, 538–557. <https://doi.org/10.1080/22797254.2021.1978001>
- The State of the World's Forests 2020. In brief, 2020. . FAO and UNEP. <https://doi.org/10.4060/ca8985en>
- Thompson, I.D., Guariguata, M.R., Okabe, K., Bahamondez, C., Nasi, R., Heymell, V., Sabogal, C., 2013. An Operational Framework for Defining and Monitoring Forest Degradation. *Ecology and Society* 18.
- Trombetti, M., Riano, D., Rubio, M., Cheng, Y., Ustin, S., 2008. Multi-temporal vegetation canopy water content retrieval and interpretation using artificial neural networks for the continental USA☆. *Remote Sensing of Environment* 112, 203–215. <https://doi.org/10.1016/j.rse.2007.04.013>
- van der Heijden, G.M., Schnitzer, S.A., Powers, J.S., Phillips, O.L., 2013. Liana Impacts on Carbon Cycling, Storage and Sequestration in Tropical Forests. *Biotropica* 45, 682–692. <https://doi.org/10.1111/btp.12060>
- Vancutsem, C., Achard, F., Pekel, J.-F., Vieilledent, G., Carboni, S., Simonetti, D., Gallego, J., Aragão, L.E.O.C., Nasi, R., 2021. Long-term (1990–2019) monitoring of forest cover changes in the humid tropics. *Sci. Adv.* 7, eabe1603. <https://doi.org/10.1126/sciadv.abe1603>
- Verbesselt, J., Hyndman, R., Newnham, G., Culvenor, D., 2010. Detecting trend and seasonal changes in satellite image time series. *Remote Sensing of Environment* 114, 106–115. <https://doi.org/10.1016/j.rse.2009.08.014>
- Verbesselt, J., Zeileis, A., Herold, M., 2012. Near real-time disturbance detection using satellite image time series. *Remote Sensing of Environment* 123, 98–108. <https://doi.org/10.1016/j.rse.2012.02.022>
- Vermeulen, L.M., Munch, Z., Palmer, A., 2021. Fractional vegetation cover estimation in southern African rangelands using spectral mixture analysis and Google Earth Engine. *Computers and Electronics in Agriculture* 182, 105980. <https://doi.org/10.1016/j.compag.2020.105980>
- Viennois, G., n.d. Viennois Gaëlle. 2011. Cartographie de la phénologie des forêts tropicales humides en Afrique centrale. Paris : AgroParisTech, 41 p. Mémoire de CEA (Certificats d'études avancées) : Géomatique : AgroParisTech 41.
- Wagner, F.H., Sanchez, A., Aidar, M.P.M., Rochelle, A.L.C., Tarabalka, Y., Fonseca, M.G., Phillips, O.L., Gloor, E., Aragão, L.E.O.C., 2020. Mapping Atlantic rainforest degradation and regeneration history with indicator species using convolutional network. *PLoS ONE* 15, e0229448. <https://doi.org/10.1371/journal.pone.0229448>
- Wagner, F.H., Sanchez, A., Tarabalka, Y., Lotte, R.G., Ferreira, M.P., Aidar, M.P.M., Gloor, E., Phillips, O.L., Aragão, L.E.O.C., 2019. Using the U-net convolutional network to map



- forest types and disturbance in the Atlantic rainforest with very high resolution images. *Remote Sens Ecol Conserv* 5, 360–375. <https://doi.org/10.1002/rse2.111>
- Watson, D.Jh., 1947. Comparative physiological studies on the growth of field crops: I. Variation in net assimilation rate and leaf area between species and varieties, and within and between years. *Annals of botany* 11.41, 41-76.
- Weiss, M., Baret, F., 2016. S2toolbox Level 2 Products: LAI, Fapar, Fcover. Institut National de la Recherche Agronomique (INRA), Avignon.
- Weiss, M., Baret, F., Smith, G.J., Jonckheere, I., Coppin, P., 2004. Review of methods for in situ leaf area index (LAI) determination. *Agricultural and Forest Meteorology* 121, 37–53. <https://doi.org/10.1016/j.agrformet.2003.08.001>
- Williams-Linera, G., 1990. Vegetation Structure and Environmental Conditions of Forest Edges in Panama. *The Journal of Ecology* 78, 356. <https://doi.org/10.2307/2261117>
- Yan, S., Xu, L., Wu, R., 2019. Automatic Classification of Glaciers from Sentinel-2 Imagery Using A Novel Deep Learning Model, in: *Proceedings of the 2019 3rd International Conference on Advances in Image Processing*. Presented at the ICAIP 2019: 2019 3rd International Conference on Advances in Image Processing, ACM, Chengdu China, pp. 155–159. <https://doi.org/10.1145/3373419.3373460>
- Zhang, L., Xia, G.-S., Wu, T., Lin, L., Tai, X.C., 2016a. Deep Learning for Remote Sensing Image Understanding. *Journal of Sensors* 2016, 1–2. <https://doi.org/10.1155/2016/7954154>
- Zhang, Liangpei, Zhang, Lefei, Du, B., 2016b. Deep Learning for Remote Sensing Data: A Technical Tutorial on the State of the Art. *IEEE Geosci. Remote Sens. Mag.* 4, 22–40. <https://doi.org/10.1109/MGRS.2016.2540798>
- Zhang, P., Ke, Y., Zhang, Z., Wang, M., Li, P., Zhang, S., 2018. Urban Land Use and Land Cover Classification Using Novel Deep Learning Models Based on High Spatial Resolution Satellite Imagery. *Sensors* 18, 3717. <https://doi.org/10.3390/s18113717>
- Zhao, D., Lv, M., Wang, P., Yang, T., An, S., 2014. Can the plant area index of a submerged vegetation canopy be estimated using digital hemispherical photography? *Agricultural and Forest Meteorology* 192–193, 69–77. <https://doi.org/10.1016/j.agrformet.2014.03.008>
- Zhao, Z., Li, W., Ciais, P., Santoro, M., Cartus, O., Peng, S., Yin, Y., Yue, C., Yang, H., Yu, L., Zhu, L., Wang, J., 2021. Fire enhances forest degradation within forest edge zones in Africa. *Nat. Geosci.* 14, 479–483. <https://doi.org/10.1038/s41561-021-00763-8>
- Zhu, X.X., Tuia, D., Mou, L., Xia, G.-S., Zhang, L., Xu, F., Fraundorfer, F., 2017. Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources. *IEEE Geosci. Remote Sens. Mag.* 5, 8–36. <https://doi.org/10.1109/MGRS.2017.2762307>

# Annexes

## A.1. Publications pendant la thèse

Articles de revues scientifiques évalués par des pairs

- Vo Quang, A., Delbart, N., Jaffrain, G., Pinet, C., Moiret, A., 2022. Detection of degraded forests in Guinea, West Africa, based on Sentinel-2 time series by inclusion of moisture-related spectral indices and neighbourhood effect. *Remote Sensing of Environment* 281, 113230. <https://doi.org/10.1016/j.rse.2022.113230>
- Jaffrain, G., Leroux, A., Vo Quang, A., Pinet, C., Dessagboli, B., Gauthier, Y., & Moiret, A. (2021). Suivi de la dynamique de l'occupation du sol en République de Guinée par imagerie satellitaire Spot: Transfert technologique pour le développement d'outils performants d'aide à la décision. *Revue Française de Photogrammétrie et de Télédétection*, 223, 59–80. <https://doi.org/10.52638/rfpt.2021.563> (Original work published 21 mai 2021)

Présentations de posters à des conférences

- Vo Quang, A., Delbart, N., Jaffrain, G., & Pinet, C. (2022, May). Combination of remote sensing and Artificial Intelligence to detect degraded forests - a deep learning approach and expert-labeled Sentinel-2 data in Guinea. *Living Planet Symposium 2022*.
- Vo Quang, A., Jaffrain, G., & Delbart, N. (2019, January). The challenge of mapping forest cover changes: forest degradation detection by optical remote sensing time series analysis. In *Geophysical Research Abstracts (Vol. 21) – EGU Assembly 2019*.

## A.2. Syllabus des formations données pendant la thèse

Tableau 24 : Formations et enseignements donnés durant la thèse. La formation et le transfert des compétences en Afrique font partie des missions d'IGN FI.

| Date                                 | Lieu                     | Contenus / Objectifs  | Activités  | Public   |
|--------------------------------------|--------------------------|---|--|--|
| Mai 2021<br>(7j)                     | N'Djamena,<br>Tchad      | Etude de l'évolution de l'occupation des sols à N'Djamena et ses environs à partir de photographies aériennes anciennes (1965 vs 2017), Renforcement des capacités du département télédétection et SIG. | - Introduction aux logiciels de télédétection, QGIS, OrfeoToolBox et SNAP (Sentinel ToolBox), introduction à la photo-interprétation, vectorisation et correction des données vectorielles<br>- Production de comptes fonciers pour N'Djamena en 1965 et 2017 afin de montrer les schémas de changement de la couverture terrestre.                      | Département SIG et télédétection du MATDHU           |
| Juin 2021<br>(7j)                    | N'Djamena,<br>Tchad      | Cartographie des risques d'inondation par imageries satellitaires radar et optiques, renforcement des capacités du département de télédétection et SIG pour la gestion des terres.                      | - Introduction aux logiciels de télédétection, QGIS, OrfeoToolBox et SNAP (Sentinel ToolBox), introduction à la photo-interprétation, vectorisation et correction de données vectorielles ; apprentissage automatique (classification Random Forest) ; traitement d'imagerie radar pour produire une cartographie des inondations en présence de nuages. | Département SIG et télédétection du MATDHU           |
| Décembre 2019 -<br>Janvier 2020 (9h) | Paris,<br>France         | Logiciels libres (Travaux dirigés)  | Manipulation d'images satellites optique et radar, photo-interprétation, initiation aux logiciels de télédétection et SIG libres (QGIS, OrfeoToolBox), techniques d'apprentissage semi-automatique (classification Random Forest)  | Master 2 TGAE, Université Paris Cité                 |
| Octobre 2019 (7j)                    | Addis-Abeba,<br>Éthiopie | Formation à l'utilisation des données Sentinel-2  | Introduction à l'imagerie radar ; introduction aux logiciels OrfeoToolBox, SNAP et QGIS<br>- Photo-interprétation, vectorisation, correction des données vectorielles ; apprentissage automatique (classification Random Forest)   | Agence éthiopienne de cartographie (EMA)             |
| Mars 2019                            | Cotonou,<br>Bénin        | Formation donnée en marge de la conférence OSFACO   | Introduction au traitement de l'imagerie SAR (Sentinel-1 et ALOS-PALSAR) et aux logiciels libres (OTB, QGIS, SentinelToolBox)  | Participants de la conférence (50 personnes formées) |
| Octobre 2018                         | Libreville,<br>Gabon     | Formation donnée en marge de la conférence J-Géo 2018   | Introduction au traitement de l'imagerie SAR (Sentinel-1 et ALOS-PALSAR) et aux logiciels libres (OTB, QGIS, SentinelToolBox)  | Participants de la conférence (20 personnes formée)  |

### A.3. Matrices d'erreur brute issue du modèle U-Net (chapitre 4)

Tableau 25 : matrices d'erreur brutes pour chaque massif. UA : précision utilisateur, PA : précision producteur, EC : erreur de commission, EO : erreur d'omission, OA : précision globale.

| Ziama | Interprétation à l'aveugle |        |       |       |      |       | Ziama | Analyse de la plausibilité |        |       |       |      |       |
|-------|----------------------------|--------|-------|-------|------|-------|-------|----------------------------|--------|-------|-------|------|-------|
| Carte | 1                          | 2      | 3     | Total | UA   | EC    | Carte | 1                          | 2      | 3     | Total | UA   | EC    |
| 1     | 100                        |        |       | 100   | 100% | 0%    | 1     | 100                        |        |       | 100   | 100% | 0%    |
| 2     | 23                         | 50     | 27    | 100   | 50%  | 50%   | 2     | 12                         | 74     | 14    | 100   | 74%  | 26%   |
| 3     |                            |        | 100   | 100   | 100% | 0%    | 3     |                            |        | 100   | 100   | 100% | 0%    |
| Total | 123                        | 50     | 127   | 300   |      |       | Total | 112                        | 74     | 114   | 300   |      |       |
| PA    | 81,3%                      | 100,0% | 78,7% |       |      |       | PA    | 89,3%                      | 100,0% | 87,7% |       |      |       |
| EO    | 18,7%                      | 0,0%   | 21,3% |       | OA   | 83,3% | EO    | 10,7%                      | 0,0%   | 12,3% |       | OA   | 91,3% |

| Diécké | Interprétation à l'aveugle |       |       |       |     |       | Diécké | Analyse de la plausibilité |       |       |       |     |       |
|--------|----------------------------|-------|-------|-------|-----|-------|--------|----------------------------|-------|-------|-------|-----|-------|
| Carte  | 1                          | 2     | 3     | Total | UA  | EC    | Carte  | 1                          | 2     | 3     | Total | UA  | EC    |
| 1      | 99                         | 1     |       | 100   | 99% | 1%    | 1      | 99                         | 1     |       | 100   | 99% | 1%    |
| 2      | 36                         | 26    | 38    | 100   | 26% | 74%   | 2      | 24                         | 63    | 13    | 100   | 63% | 37%   |
| 3      |                            | 5     | 95    | 100   | 95% | 5%    | 3      |                            | 4     | 96    | 100   | 96% | 4%    |
| Total  | 135                        | 32    | 133   | 300   |     |       | Total  | 123                        | 68    | 109   | 300   |     |       |
| PA     | 73,3%                      | 81,3% | 71,4% |       |     |       | PA     | 80,5%                      | 92,6% | 88,1% |       |     |       |
| EO     | 26,7%                      | 18,8% | 28,6% |       | OA  | 73,3% | EO     | 19,5%                      | 7,4%  | 11,9% |       | OA  | 86,0% |

| Nimba | Interprétation à l'aveugle |       |       |       |     |       | Nimba | Analyse de la plausibilité |       |       |       |     |       |
|-------|----------------------------|-------|-------|-------|-----|-------|-------|----------------------------|-------|-------|-------|-----|-------|
| Carte | 1                          | 2     | 3     | Total | UA  | EC    | Carte | 1                          | 2     | 3     | Total | UA  | EC    |
| 1     | 96                         | 3     | 1     | 100   | 96% | 4%    | 1     | 96                         | 3     | 1     | 100   | 96% | 4%    |
| 2     | 16                         | 54    | 30    | 100   | 54% | 46%   | 2     | 4                          | 75    | 21    | 100   | 75% | 25%   |
| 3     |                            | 14    | 86    | 100   | 86% | 14%   | 3     |                            | 4     | 96    | 100   | 96% | 4%    |
| Total | 112                        | 71    | 117   | 300   |     |       | Total | 100                        | 82    | 118   | 300   |     |       |
| PA    | 85,7%                      | 76,1% | 73,5% |       |     |       | PA    | 96,0%                      | 91,5% | 81,4% |       |     |       |
| EO    | 14,3%                      | 23,9% | 26,5% |       | OA  | 78,7% | EO    | 4,0%                       | 8,5%  | 18,6% |       | OA  | 89,0% |

Tableau 22 : matrice brute globale.

| Global | Interprétation à l'aveugle |       |       |       |     |       | Global | Analyse de la plausibilité |       |       |       |     |       |
|--------|----------------------------|-------|-------|-------|-----|-------|--------|----------------------------|-------|-------|-------|-----|-------|
| Carte  | 1                          | 2     | 3     | Total | UA  | EC    | Carte  | 1                          | 2     | 3     | Total | UA  | EC    |
| 1      | 295                        | 4     | 1     | 300   | 98% | 2%    | 1      | 295                        | 4     | 1     | 300   | 98% | 2%    |
| 2      | 75                         | 130   | 95    | 300   | 43% | 57%   | 2      | 40                         | 212   | 48    | 300   | 71% | 29%   |
| 3      |                            | 19    | 281   | 300   | 94% | 6%    | 3      |                            | 8     | 292   | 300   | 97% | 3%    |
| Total  | 370                        | 153   | 377   | 900   |     |       | Total  | 335                        | 224   | 341   | 900   |     |       |
| PA     | 79,7%                      | 85,0% | 74,5% |       |     |       | PA     | 88,1%                      | 94,6% | 85,6% |       |     |       |
| EO     | 20,3%                      | 15,0% | 25,5% |       | OA  | 78,4% | EO     | 11,9%                      | 5,4%  | 14,4% |       | OA  | 88,8% |

## A.4 Table des illustrations

### A.4.1. Figures

|  |    |
|--|----|
| Figure 1 : forêt dense non perturbée (en haut à gauche) et cinq principaux facteurs de dégradation forestière : feux de forêt (et cultures sur brûlis), coupe sélective pour les bois nobles, collecte de bois de chauffage, maladie et pâturage animal qui empêche la régénération forestière. ....   | 17 |
| Figure 2 : proportion des émissions de GES dues à la dégradation des forêts pour les 74 pays inclus dans l'étude de Pearson et al. (2017). ....  | 18 |
| Figure 3 : Courbe de succession forestière extraite de Morales-Barquero et al. (2014). ....  | 22 |
| Figure 4 : Carte 2015 de l'occupation et de l'utilisation des sols (OCS) de la Guinée montrant la localisation du site d'étude dans les massifs de Ziama, Diécké et Nimba, avec une forêt pluviale exposée à la mousson. La carte OCS 2015 a été produite dans le cadre du projet Zonage Agro-écologique de la Guinée (ZAEG), avec 47 classes adaptées de l'European Corine Land Cover. Les cartes présentées dans tout le manuscrit sont projetées au UTM zone 29 nord, sur l'ellipsoïde WGS 1984. Source : projet ZAEG (voir partie 2.2). ....   | 30 |
| Figure 5 : Carte 2015 de l'occupation et de l'utilisation des sols (OCS) de la Guinée forestière. Source : projet ZAEG. ....   | 31 |
| Figure 6 : Carte 2015 de l'occupation des sols (OCS) de la zone d'étude de Ziama. Source : projet ZAEG. ....   | 32 |
| Figure 7 : illustrations de référence des forêt dense et dégradées dans le guide technique du projet ZAEG. A gauche : forêt dense sur une image SPOT-6 en 2016 (6 m de résolution). A droite : forêt dégradée sur la même image. ....  | 35 |
| Figure 8 : Image Google Earth (9°15'32.41"O, 8°10'49.72"N). Forêt dense (carré B) et forêt dégradée (carré A). ....  | 36 |
| Figure 9 : agroforêts (orange). Compositions colorées Sentinel-2 (PIR/MIR/R). ....   | 37 |
| Figure 10 : plantations d'hévéas (rouge foncé). Compositions colorées Sentinel-2 (PIR/MIR/R). ....   | 37 |
| Figure 11 : incertitudes de la classe forêt dégradée observées dans la carte ZAEG (en haut). La carte ZAEG 2015 présente des défauts sur la classe de forêt dégradée, qui est faiblement visible sur l'image SPOT6 (au milieu). En bas, photographie de l'interface forêt/non-forêt (étoile verte), Ziama le 25 avril 2019. Source : An Vo Quang. ....   | 39 |
| Figure 12 : collecte des données terrain, forêt de Ziama (photographie prise le 25 avril 2019). ....   | 40 |
| Figure 13 : a) Carte ZAEG de 2015 de la zone d'étude dans le massif de Ziama, à partir de l'image SPOT-6 12/09/2015 ; b) enquêtes de terrain réalisées sur les 4 transects. Les points de contrôle au sol dans les transects sont représentés par des triangles. L'analyse est affinée sur les pixels dans les transects (vert : forêt dense ; jaune : forêt dégradée ; rose : forêt sévèrement dégradée). ....  | 41 |
| Figure 14 : piège pour petits mammifères, forêt de Ziama (25 avril 2019). ....   | 42 |
| Figure 15 : fruits du palmier <i>Elaeis guineensis</i> trouvés en forêt dégradée. Photographies prises le 26 avril 2019. ....  | 42 |
| Figure 16 : fruits du palmier <i>Elaeis guineensis</i> avant transformation (gauche) puis transformés en huile de palme (droite), en bordure de forêt, Ziama (26 avril 2019). Source : An Vo Quang. ....   | 43 |
| Figure 17 : lianes en forêt dégradée (photographie prise le 26 avril 2019). ....   | 44 |
| Figure 18 : présence de trouées dans la canopée supérieure et lianes en forêt dégradée (photographies prises le 26 avril 2019). ....   | 44 |
| Figure 19 : schéma d'un transect d'observation de forêt d'interface. ....  | 45 |
| Figure 20 : photographies hémisphériques dans une forêt dense (série 1, en haut) et une forêt dégradée (série 2, en bas). Dans cette dernière, les trouées de la canopée, créées par la chute d'arbres et les coupes sélectives, conduisent à de nouvelles conditions environnementales de plus grande disponibilité de la lumière (2a), entraînant la colonisation des lianes (2b) et l'émergence d'espèces héliophiles pionnières comme les palmiers <i>Elaeis guineensis</i> (2c). Dans une forêt dense sans trace de perturbation, très peu de lumière solaire traverse la canopée (1a, 1b et 1c). Photos prises dans le massif du Ziama (8°14'22« 2 "N, 9°21'44« 0 "W) le 21 avril 2019. .... | 47 |

|  |    |
|--|----|
| Figure 21 : Fraction de trou (« gap fraction ») sur chaque relevé de terrain dans les 4 transects. Le départ de chaque transect (relevé n°1) se situe aux lisières de forêt. ....  | 48 |
| Figure 22 : schéma des différences structurelles observées entre les forêts denses et les forêts dégradées sur le terrain en Guinée forestière. La composition de la forêt est modifiée dû à l'exploitation sélective : l'abondance en espèces commerciales diminue tandis que celle des espèces secondaires dans les trouées d'exploitation augmente. ....  | 49 |
| Figure 23 : Processus de dégradation basé sur les observations de terrain de Ziama et les témoignages des gardes forestiers locaux. ....   | 50 |
| Figure 24 : Les emprises des images Sentinel-2 sur la Guinée Forestière (en vert) et le reste de la Guinée (en bleu). Les massifs forestiers de Ziama, Diécké et Nimba sont indiqués en rouge. ....  | 52 |
| Figure 25 : comparaison des compositions colorées utilisées pour photo-interpréter les forêts dégradées sur SPOT6 (PIR/rouge/vert) dans le projet ZAEG et celle proposée pour Sentinel-2 (PIR/MIR/rouge) en 2015 (gauche). La photo-interprétation sur Sentinel-2 est facilitée par l'examen d'images Sentinel-2 à d'autres dates. Exemple pris au point de coordonnées : 9°15'32.41"O, 8°10'49.72"N.....  | 54 |
| Figure 26 : séries temporelles des réflectances dans les bandes vert (B3), PIR (B8), rouge (B4) et MIR (B11) de Sentinel-2 de 2015 à 2019, en saison sèche, sur des échantillons choisis sur la carte ZAEG (plantations d'arbres en marron, agroforêts en orange, forêts de massif en vert foncé), et à partir d'observations au sol dans des forêts en transect (une partie dans le massif, la 2ème intermédiaire proche du massif, la 3ème proche des zones ouvertes). L'emplacement des pixels est indiqué sur la figure 13. .... | 55 |
| Figure 27 : composition colorée Sentinel-2 générée en combinant les bandes PIR, MIR et rouge dans les canaux rouge, vert et bleu respectivement. La forêt dégradée (A) présente des tons orange et rouge plus « verts » que les forêts denses (B) ; elle se trouve en lisière de terres cultivées et donc plus exposée aux interventions humaines. ....  | 56 |
| Figure 28 : annotation des classes par photo-interprétation. ....  | 57 |
| Figure 29 : cartes photo-interprétées des données Sentinel-2 en a) 2015, b) 2017, c) 2019 & d) 2020. L'état de la forêt est celui observé sur le terrain en avril 2019 dans les points de contrôles (triangles). ....  | 58 |
| Figure 30 : schéma représentant deux pixels purs et un pixel mélangé dans une carte d'OCS. ....  | 68 |
| Figure 31 : Signatures spectrales de pixels « purs » sur de la végétation photosynthétiques, de la végétation non-photosynthétique, du sol et de l'eau. L'exemple est pris sur l'image du 15/02/2019. Dans une image en abondances, chaque pixel « mélangé » est une combinaison linéaire de ces 4 membres purs. ....  | 71 |
| Figure 32 : Analyse multi-temporelle des valeurs d'abondance des 4 membres finaux de l'analyse subpixelaire SMA sur les forêts dense (rouge) et dégradée (vert) entre 2016 et 2019. Les pixels analysés ont été sélectionnés sur les forêts denses et les forêts dégradées de la carte ZAEG.....   | 72 |
| Figure 33 : schéma simplifié de l'algorithme Random Forest. ....   | 73 |
| Figure 34 : A) composition colorée des fractions SMA extraites des radiométries de S2 de 2015 (fraction de Végétation verte, fraction de Végétation non photosynthétique et fraction de Sol dans les canaux RVB respectivement) ; B) résultat de classification multitudes à partir de 10 images d'abondances SMA entre 2015 et 2017 ; C) carte de référence photo-interprétée de 2017, à laquelle sont superposés les transects de la campagne de terrain de 2019. ....   | 75 |
| Figure 35 : localisation des deux séries de membres finaux de référence. ....  | 76 |
| Figure 36 : résultat brut de classification multitemporelle SMA (22 dates), à partir de 2 séries différentes de membres finaux de référence. 3 agrandissements sont illustrés par des rectangles sur la carte. ....  | 78 |
| Figure 37 : séries temporelles NDVI, SAVI, EVI, SIWSI et MSI générés à partir de Sentinel-2 de fin 2015 à début 2019, en saison sèche, sur des échantillons de type de forêt, choisis sur la carte ZAEG (plantations d'arbres en marron, agroforêts en orange, forêts de massif en vert foncé), et à partir d'observations au sol dans des forêts en transect divisées en 2 parties (une partie plus proche du massif forestier, l'autre en bordure). L'emplacement des pixels est indiqué sur la figure 13. ....                    | 79 |
| Figure 38 : des séries temporelles d'indices de télédétection sur les échantillons de type de forêt, choisis sur la carte ZAEG (plantations d'arbres en marron, agroforêts en orange, forêts de massif en vert foncé), et à partir d'observations au sol dans des forêts en transect divisées en 2 parties (une partie plus proche du massif forestier, l'autre en bordure). L'emplacement des pixels est indiqué sur la figure 4. Les indices   |    |

|   |     |
|---|-----|
| de télédétection sont : l'indice de stress hydrique (MSI), le contenu en eau de la canopée (CWC) et l'indice de surface foliaire (LAI), calculés pour chaque image Sentinel 2 (tableau 4).....  | 81  |
| Figure 39 : exemple de parcelles carrées sélectionnées aléatoirement sur l'image pour l'entraînement du modèle. Les pixels d'apprentissage sont en gris foncé ; les pixels de validation en gris clair et les pixels noirs dans les zones tampons (10 pixels) sont supprimés pour éviter l'autocorrélation spatiale entre l'apprentissage et la validation.....   | 84  |
| Figure 40 : (i) Calcul des indices MSI, LAI et CWC à partir des bandes Sentinel-2 brutes ; (ii) annotation de chaque pixel (forêt dense, forêt dégradée, autre), et séparation en jeux de données d'entraînement et de validation ; (iii) Conversion des données images en tableau ; entraînement du modèle RF (iv) Classification de l'image 2020.....   | 84  |
| Figure 41 : méthode basée sur les pixels voisins. (i) Dérivation du MSI, du LAI et du CWC à partir des bandes Sentinel-2; combinaison de toutes les bandes en un raster ; (ii) production de la carte photo-interprétée (forêt dense, forêt dégradée, autre), puis extraction des jeux de données d'entraînement (colonne gauche) ; (iii) extraction des pixels voisins par une fenêtre glissante, (iv) conversion des données matricielles en données tabulaires avant entraînement du modèle ; application du modèle sur le reste de l'image (colonne droite) (v) validation du résultat de classification.....   | 85  |
| Figure 42 : Tests sur le pourcentage de photo-interprétation requis sur des données antérieures à 2020 et/ou des données de 2020 pour classer la forêt dégradée de 2020. a) Classification 2020 à partir de la donnée 2015, avec et sans contribution de 2020 dans les données d'entraînement. b) Classification 2020 à partir des 4 données annuelles antérieures, avec et sans contribution de 2020 dans les données d'entraînement. c) Classification des données 2020 sans entraînement autre que les données photo-interprétées de l'image 2020 elle-même. d) Classification d'une nouvelle région, Nimba, avec et sans contribution de la donnée Nimba dans les données d'entraînement. Les deux méthodes, basées sur les pixels standard et les pixels voisins, sont testées. Dans chaque cas, les pixels d'entraînement sont choisis au hasard..... | 87  |
| Figure 43 : Les images de classification obtenues avec la méthode des pixels voisins sont affichées lorsque 0%, 1.6% et 25.8% des données 2020 S2 sont jointes aux données 2015 et utilisées comme entrée pour la classification.....   | 88  |
| Figure 44 : comparaison des deux méthodes de classification avec la carte photo-interprétée (c) : a) méthodes basées sur les pixels (OA = 0.867) et b) méthodes basées sur les pixels voisins (OA= 0.896). Les résultats sont présentés avec 1,6 % (c'est-à-dire, parcelles carrées de 1 x 1 km) des données photo-interprétées de l'image S2 de 2020 utilisées comme données d'entraînement.....   | 91  |
| Figure 45 : Mont Nimba. A : résultat de classification sans voisinage pixellaire. B : avec voisinage pixellaire. C : composition colorée Sentinel-2.....  | 92  |
| Figure 46 : exemples d'images SpaceNet labellisées pour l'extraction automatisée d'empreinte de bâtiment. En rouge, le bâti ; en bleu, non bâti.....  | 98  |
| Figure 47 : flux de travail pour le chapitre 4.....   | 99  |
| Figure 48 : Génération des données d'entrées qui comprennent les bandes brutes Sentinel-2, les indices liés à l'humidité (MSI, CWC), l'indice de surface foliaire (LAI), et les cartes photo-interprétées correspondantes.....  | 103 |
| Figure 49 : schéma des sous-ensembles de l'intelligence artificielle. Les réseaux de neurones convolutifs (CNN) appartiennent au sous-ensemble du deep learning.....  | 104 |
| Figure 50 : analogie entre un neurone biologique et un « perceptron » de réseau de neurones convolutifs. Adapté de Hands on Mathematics for Deep Learning (Dawani, 2020).....   | 104 |
| Figure 51 : schéma de couches de neurones. Source : Hands on Mathematics for Deep Learning (Dawani).....  | 105 |
| Figure 52 : l'architecture U-Net pour la segmentation sémantique, modifiée à partir de Ronneberger et al. (2015).....   | 107 |
| Figure 53 : Une concaténation (flèche en gris) en bas du U. Repris de Ronneberger et al. (2015). ....   | 108 |
| Figure 54 : exemple de la représentation interne du modèle U-Net avec les cartes d'activation extraites de chacun des blocs du réseau sur un filtre donné.....  | 108 |
| Figure 55 : architecture SegNet. Source : Badrinarayanan et al., 2017.....  | 109 |
| Figure 56 : un bloc résiduel de ResNet. Source : He et al., 2016.....   | 110 |

|  |     |
|--|-----|
| Figure 57 : Architecture de ResNet-UNet. La structure du ResNet-UNet utilise la structure U-Net, qui comprend des parties d'encodeur (sous-échantillonnage) et de décodeur (sur-échantillonnage). L'encodeur de sous-échantillonnage est remplacé par le modèle ResNet. Source : Charng et al., 2020. ....   | 110 |
| Figure 58 : Stratification et sites de validation de surface de 1 ha (carrés rouges) dans les massif de Nimba, Diecke et Ziama en 2021. Dans la ligne du bas, des agrandissements sont donnés pour chaque massif.....  | 114 |
| Figure 59 : plantations d'hévéas (cercles noirs) sur le massif de Diécké entre 2017 et 2021. ....  | 118 |
| Figure 60 : avant et sans normalisation sur le massif de Diécké et le mont Nimba.....  | 119 |
| Figure 61 : comparaison de la carte photo-interprétée de Ziama 2021 (en haut à gauche), les cartes issues des méthodologies Random Forest du chapitre 3 appliquées à 2021 (en haut, au milieu et à droite) et les cartes issues des 3 réseaux deep learning U-Net, SegNet et Resnet-Unet du chapitre 4. Les précisions globales (OA) de la validation externe sont données. A gauche, l'image Sentinel-2 2021 en composition colorée PIR/MIR/R.....                    | 130 |
| Figure 62 : comparaison de la carte photo-interprétée de Nimba 2021 (2 <sup>e</sup> ligne, à gauche), les cartes issues des méthodologies Random Forest du chapitre 3 appliquées à l'image S2 2021 et les cartes issues des 3 réseaux deep learning U-Net, SegNet et Resnet-Unet du chapitre 4 (dernière ligne). Les précisions globales (OA) de la validation externe sont indiquées. En haut à gauche, l'image Sentinel-2 2021 en composition colorée PIR/MIR/R..... | 134 |
| Figure 63 : deux formes de forêts dégradées en République du Congo. A gauche : les cimes de la strate arborescente ne sont plus contiguës et sont toujours constituées d'espèces d'arbres endémiques locales. A droite : régénération exclusive de la forêt à croissance rapide de Musanga Cecropioides, après un événement de déforestation. ....   | 135 |
| Figure 64 : fusion d'images radar ALOS-PALSAR 2 et optiques Sentinel-2.....  | 137 |

#### A.4.2. Tableaux

|   |     |
|---|-----|
| Tableau 1 : Caractéristiques des bandes spectrales de l'image SPOT-6 du 12/09/2015.....   | 34  |
| Tableau 2 : relevés terrain de la campagne avril 2019. ....   | 41  |
| Tableau 3 : Caractéristiques des bandes spectrales de Sentinel-2. Les bandes 2 à 8A, 11 et 12 ont été utilisées pour cette étude (surlignées en gris). ....   | 51  |
| Tableau 4 : Images Sentinel-2 utilisées dans cette étude sur Ziama. 23 images acquises entre fin 2015 et 2020 ont été utilisées pour 1) l'analyse temporelle des changements radiométriques du couvert forestier, sur une petite fenêtre d'acquisition de décembre à février en saison sèche, permettant la comparabilité des données, et pour la production de cartes de forêts dégradées par les méthodes semi-automatiques développées aux chapitres 3 et 4 ; 2) une image a été conservée pour chaque année et une photo-interprétation a été réalisée pour produire des cartes de forêt dégradée de référence annuelle. .... | 53  |
| Tableau 5 : Statistiques de l'évaluation des deux méthodes de classification entraînées sur l'année 2015 et appliquées sur l'année 2020. Les indicateurs d'évaluation du modèle incluent la précision globale (OA) pour la classification globale et les précisions utilisateur et producteur pour chaque classe. ....  | 90  |
| Tableau 6 : Statistiques de l'évaluation des deux méthodes de classification entraînées sur les années 2015/2017/2018/2019 et appliquées sur l'année 2020. ....   | 90  |
| Tableau 7 : Statistiques de l'évaluation des deux méthodes de classification entraînées sur l'année 2020 à Ziama sans aucune connaissance préalable des cartes antérieures. ....  | 93  |
| Tableau 8 : Statistiques de l'évaluation des méthodes de classification entraînées sur l'année 2020 à Ziama et appliquées sur l'année 2020 à Nimba.....   | 93  |
| Tableau 9 : données images Sentinel-2 photo-interprétées et utilisées pour l'entraînement des modèles CNN ou leur évaluation.....   | 102 |
| Tableau 10 : paramètres d'entraînement pour la comparaison des modèles.....   | 112 |



|  |     |
|--|-----|
| Tableau 11 : Tests sur la taille du jeu d'entraînement pour classer la forêt dégradée de 2021. a) Classification 2021 à partir d'une image, i.e. la donnée 2015 ou b) la donnée 2020 dans les données d'entraînement. c) Classification des données 2021 avec 2 images d'entraînement. d) Classification 2021 à partir des 4 données antérieures dans les données d'entraînement. e) Classification des données 2021 en utilisant 2 images de 2 massifs différents dans les données d'entraînement. .... | 112 |
| Tableau 12 : valeurs maximales sur la série temporelle utilisées pour la normalisation des données. ....   | 113 |
| Tableau 13 : 2 équipes de validation pour une 1ère puis une 2ème photo-interprétation des sites. ....  | 115 |
| Tableau 14 : surfaces et poids des classes dans chaque massif pour la matrice d'erreur normalisé ...   | 116 |
| Tableau 15 : lecture d'une matrice de confusion normalisée. ....   | 116 |
| Tableau 16 : Précisions globales du réseau U-Net appliqué sur les 3 massifs en 2021. Le nombre d'époques lorsque le modèle est arrêté est aussi précisé. ....  | 117 |
| Tableau 17 : Statistiques des 3 modèles CNN sur les 3 massifs en 2021, sans normalisation des données. ....  | 118 |
| Tableau 18 : Statistiques des 3 modèles CNN sur les 3 massifs en 2021, avec normalisation des données. ....  | 119 |
| Tableau 19 : durée de traitement et statistiques du réseau U-Net des classifications sur les 3 massifs sur l'année 2021. PA = précision producteur ; UA = précision utilisateur. ....  | 120 |
| Tableau 20 : : matrices d'erreur normalisées pour chaque massif. UA : précision utilisateur, PA : précision producteur, EC : erreur de commission, EO : erreur d'omission, OA : précision globale. ....  | 122 |
| Tableau 21 : matrice d'erreur normalisée globale. ....   | 122 |
| Tableau 22 : matrices d'erreur brutes et normalisées pour la carte photo-interprétée <b>Ziama</b> 2021, pour les 3 modèles CNN (U-Net, SegNet, Resnet-Unet) et pour les 2 modèles Random Forest avec et sans contexte régional dans l'algorithme. UA : précision utilisateur, PA : précision producteur, EC : erreur de commission, EO : erreur d'omission, OA : précision globale. Les indicateurs sont calculés par comparaison aux 300 points de la validation externe décrite au chapitre 4. ....    | 128 |
| Tableau 23 : matrices d'erreur brutes et normalisées pour la carte photo-interprétée <b>Nimba</b> 2021, les 3 modèles CNN (U-Net, SegNet, Resnet-Unet) et les 4 modèles Random Forest avec et sans contexte régional dans l'algorithme, avec et sans Nimba dans l'apprentissage. UA : précision utilisateur, PA : précision producteur, EC : erreur de commission, EO : erreur d'omission, OA : précision globale. ....  | 132 |
| Tableau 24 : Formations et enseignements donnés durant la thèse. La formation et le transfert des compétences en Afrique font partie des missions d'IGN FI. ....   | 154 |
| Tableau 25 : matrices d'erreur brutes pour chaque massif. UA : précision utilisateur, PA : précision producteur, EC : erreur de commission, EO : erreur d'omission, OA : précision globale. ....   | 155 |