

Faculté des bioingénieurs

Suivi de la déforestation tropicale à l'aide des données SAR en bande C du satellite Sentinel-1A

Zone d'étude : Pokola, République du Congo

Auteur : Aline Denis

Promoteur : Pr. Pierre Defourny

Lecteurs : Pr. Sophie Bontemps

Pr. Quentin Ponette

Année académique 2020-2021

Mémoire de fin d'études présenté en vue de l'obtention du diplôme de

Bioingénieur : sciences et technologies de l'environnement

Remerciements

Avant toute chose, j'aimerais remercier mon promoteur, Pierre Defourny, pour son accompagnement tout au long de la réalisation de ce mémoire, pour ses enseignements sur la télédétection et pour ses précieux conseils pour la rédaction.

Je tiens particulièrement à remercier Baptiste Delhez pour son aide indispensable, pour sa disponibilité, pour sa guidance dans le choix de ma zone d'étude et de ma méthodologie et pour son encadrement.

J'aimerais également remercier Nicolas Deffense pour son apprentissage aux TP de land monitoring, et pour m'avoir débloqué de nombreux passages de code.

Je tiens à saluer mes lecteurs, Sophie Bontemps et Quentin Ponette pour les remercier d'avoir pris le temps de lire ce travail avec attention.

J'aimerais remercier Juliette Dalimier, qui m'a aidé à réaliser mon choix de sujet de mémoire et m'a fourni de bonnes recommandations.

J'aimerais remercier Jean Bouchat pour les informations fournies sur Sentinel-1 et pour ses conseils

J'aimerais également remercier Benjamin Goffart et Thomas de Maet pour leur aide précieuse durant l'élaboration du code ayant produit mes résultats.

En général, je tiens à remercier l'ensemble des professeurs et des chercheurs du laboratoire de Géomatique de m'avoir permis de réaliser ce travail dans un cadre motivant et enthousiaste.

Je salue également la présence de Audric Bos, Émilien Juckler, Victoria Vanderlinden et Thibault Castin, qui m'ont accompagné au début de mes recherches.

Enfin, je souhaite remercier vivement mes parents, pour leurs encouragements, pour leur soutien financier durant mes études et pour leur soutien moral durant cette période de COVID.

Table des matières

Introduction.....	1
Chapitre 1 : Synthèse bibliographique	2
1) Impacts environnementaux et socio-économiques de la déforestation	2
2) État des lieux de la forêt tropicale dans la République du Congo.....	2
3) État de l’art de la recherche sur le suivi de la déforestation par télédétection.....	4
a) Recherche antérieure au 21e siècle	4
b) Suivi des changements d’occupation du sol à l’aide des satellites Landsat.....	5
c) Combinaison des images issues de différentes missions satellitaires	6
d) Combinaison des satellites S1 et S2	8
4) La recherche sur l’utilisation des satellites S1 pour le suivi de la déforestation.....	9
5) Description du satellite S1.....	11
6) Conclusion	13
Chapitre 2 : Objectifs.....	15
Chapitre 3 : Matériel et méthodes.....	16
1) Contexte socio-économique	17
2) Climat.....	20
3) Topographie	20
4) Sources de données	21
a) Acquisition et prétraitement des données d’amplitude	21
b) Acquisition et prétraitement des données de cohérence.....	24
5) Méthodologie d’analyse des séries temporelles.....	24
a) Analyse préalable des résolutions spatiales de 10m et 20m	25
b) Calcul de métriques.....	26
c) Normalisation	26
d) Analyse de la qualité du signal	26
e) Métriques des séries temporelles.....	27
f) Sélection des variables les plus informatives	28
g) Classification.....	29
h) Validation	32
Chapitre 4 : Résultats et interprétation	33
a) Analyse préalable des résolutions spatiales de 10m et 20m	33
b) Calcul de métriques.....	33
c) Normalisation	35
d) Analyse de la qualité du signal	36
e) Métriques des séries temporelles.....	39
f) Sélection des variables les plus informatives	45

g) Classification	49
h) Validation	56
Chapitre 5 : Discussion	62
1) Comparaison des performances des 2 types de classification.....	62
2) Extraction du bruit.....	64
3) Confrontation des résultats avec la littérature scientifique	66
4) Produit final	67
Conclusion et perspectives.....	70
Bibliographie.....	73
Annexes	I
1) Rétrodiffusion sur 4 ans sur des surfaces stables en polarisation VH.....	II
2) Classifications	III
a) Par pixel	III
b) Par objet	VI
3) Tableau des performances des classifications et du nombre de polygones et de pixels de calibration et de validation.....	IX

Liste des figures

FIGURE 1 : ZONES PROTEGEES ET CONCESSIONS FORESTIERES DANS LA REPUBLIQUE DU CONGO	3
FIGURE 2 : INTERVALLE DE REVISITE DE S1 DANS LE MONDE (EO OPEN SCIENCE, 2019).....	12
FIGURE 3 : LOCALISATION DE LA ZONE D'ETUDE ; (A) LOCALISATION DE OUESSO, (B) LOCALISATION DE POKOLA	16
FIGURE 4 : UFA DE POKOLA (SOURCE : OLAM, 2016).....	18
FIGURE 5 : UNITES FORESTIERES DE PRODUCTION DE L'UFA POKOLA (OLAM, 2016)	19
FIGURE 6 : VOLUME TOTAL DE PRODUCTION DE BOIS SUR LA CONCESSION FORESTIERE DE POKOLA (OFAC, CONSULTE EN 2021)	19
FIGURE 7 : DIAGRAMME OMBROTHERMIQUE DE POKOLA (CLIMATE-DATA, CONSULTE EN 2021)	20
FIGURE 8 : TOPOGRAPHIE DE LA ZONE D'ETUDE	21
FIGURE 9 : REPARTITION SPATIALE DES PENTES SUR LA ZONE D'ETUDE	23
FIGURE 10 : PLAGES D'ARTEFACTS CONTENUES DANS L'IMAGE S1 OBTENUE LE 15/11/2020, LIEES PROBABLEMENT A DES ORAGES LOCAUX.....	24
FIGURE 11 : ORGANIGRAMME PRESENTANT LA METHODOLOGIE DE SUIVI DE LA DEFORESTATION A L'AIDE DE DONNEES S1	25
FIGURE 12 : SELECTION DE POLYGONES DE SURFACE STABLE UTILISES POUR ANALYSER LE BRUIT DU SIGNAL DE RETRODIFFUSION	27
FIGURE 13 : ÉVOLUTION DU SIGNAL DES MEDIANES SEMESTRIELLES NORMALISEES EN POLARISATION VV ENTRE 2018 ET 2020 SUR DES POLYGONES DE FORET DEGRADEE	27
FIGURE 14 : POLYGONES DE FORET STABLE ET DE DEFORESTATION UTILISES POUR CONSTRUIRE LES SERIES TEMPORELLES	28
FIGURE 15 : ILLUSTRATION DU FILTRE MEDIAN APPLIQUE AUX METRIQUES	29
FIGURE 16 : COMPOSITION COLOREE DE METRIQUES ANNUELLES REPRESENTANT LE CHANGEMENT DU COUVERT FORESTIER EN 2020 (B1 : MOYENNE VH, B2 : MEDIANE VH, B3 : ECART-TYPE VH)	29
FIGURE 17 : COURBE GAUSSIENNE REPRESENTANT LES PROBABILITES D'ETRE UNE SURFACE FORESTIERE, SELON LA METHODE DE REICHE ET AL. (2015) (EPSILON THEORY, CONSULTE LE 06/06/2021)	30
FIGURE 18 : POLYGONES DE FORET STABLE ET DE DEFORESTATION UTILISES POUR ENTRAINER LES CLASSIFICATIONS	31
FIGURE 19 : SEGMENTATION A 20M DE RESOLUTION SPATIALE SUR UNE COMPOSITION COLOREE DE 10M DE RESOLUTION ; (A) POLYGONE SEGMENTE CORRECTEMENT A 20M DE RESOLUTION, (B) POLYGONE SEGMENTE LARGEMENT A 20M DE RESOLUTION, (C) POLYGONE SEGMENTE CORRECTEMENT A 10M DE RESOLUTION.	33
FIGURE 20 : REPRESENTATION DES Q10 ANNUELS DE 2019 DANS LES 3 POLARISATIONS SOUS LA FORME D'UNE COMPOSITION COLOREE ; (R) POLARISATION VV, (B) POLARISATION VH, (G) RATIO VV/VH	34
FIGURE 21 : EFFET DE LA NORMALISATION SUR LA VALEUR DES PIXELS DE LA MOYENNE ANNUELLE DE 2019 EN POLARISATION VV	35
FIGURE 22 : ÉVOLUTION DU SIGNAL DES MEDIANES TRIMESTRIELLES EN POLARISATION VV ENTRE 2018 ET 2020 SUR DES POLYGONES DE FORET STABLE	36
FIGURE 23 : ÉVOLUTION DU SIGNAL DES MEDIANES TRIMESTRIELLES NORMALISEES EN POLARISATION VV ENTRE 2018 ET 2020 SUR DES POLYGONES DE FORET STABLE	36
FIGURE 24 : ÉVOLUTION DU SIGNAL MOYEN DE RETRODIFFUSION EN POLARISATION VV SUR DES SURFACES STABLES SUR UNE PERIODE DE 4 ANS.....	38
FIGURE 25 : ÉVOLUTION DU SIGNAL DES MOYENNES TRIMESTRIELLES NORMALISEES EN POLARISATION VH ENTRE 2018 ET 2020 SUR DES POLYGONES DE DEFORESTATION	39
FIGURE 26 : ÉVOLUTION DU SIGNAL DES MOYENNES TRIMESTRIELLES NORMALISEES EN POLARISATION VV ENTRE 2018 ET 2020 SUR DES POLYGONES DE DEFORESTATION	39
FIGURE 27 : ÉVOLUTION DU SIGNAL DES MEDIANES TRIMESTRIELLES NORMALISEES EN POLARISATION VH ENTRE 2018 ET 2020 SUR DES POLYGONES DE DEFORESTATION	40
FIGURE 28 : ÉVOLUTION DU SIGNAL DES MEDIANES TRIMESTRIELLES NORMALISEES EN POLARISATION VV ENTRE 2018 ET 2020 SUR DES POLYGONES DE DEFORESTATION	40
FIGURE 29 : ÉVOLUTION DU SIGNAL DES QUANTILES 10 TRIMESTRIELS NORMALISES EN POLARISATION VH ENTRE 2018 ET 2020 SUR DES POLYGONES DE DEFORESTATION	41
FIGURE 30 : ÉVOLUTION DU SIGNAL DES QUANTILES 10 TRIMESTRIELS NORMALISES EN POLARISATION VV ENTRE 2018 ET 2020 SUR DES POLYGONES DE DEFORESTATION	41
FIGURE 31 : ÉVOLUTION DU SIGNAL DES QUANTILES 90 TRIMESTRIELS NORMALISES EN POLARISATION VH ENTRE 2018 ET 2020 SUR DES POLYGONES DE DEFORESTATION	42
FIGURE 32 : ÉVOLUTION DU SIGNAL DES QUANTILES 90 TRIMESTRIELS NORMALISES EN POLARISATION VV ENTRE 2018 ET 2020 SUR DES POLYGONES DE DEFORESTATION	42
FIGURE 33 : ÉVOLUTION DU SIGNAL DE LA COHERENCE NORMALISEE EN POLARISATION VV SUR L'ANNEE 2019, SUR DES POLYGONES DE DEFORESTATION	43
FIGURE 34 : ÉVOLUTION DU SIGNAL DE LA COHERENCE NORMALISEE EN POLARISATION VH SUR L'ANNEE 2019, SUR DES POLYGONES DE DEFORESTATION	44
FIGURE 35 : ÉVOLUTION DU SIGNAL DES MOYENNES ANNUELLES NORMALISEES EN POLARISATION VV ENTRE 2018 ET 2020 SUR DES POLYGONES DE DEFORESTATION	44
FIGURE 36 : ÉVOLUTION DU SIGNAL DES MOYENNES SEMESTRIELLES NORMALISEES EN POLARISATION VV ENTRE 2018 ET 2020 SUR DES POLYGONES DE DEFORESTATION	44
FIGURE 37 : ÉVOLUTION DU SIGNAL DES MOYENNES TRIMESTRIELLES NORMALISEES EN POLARISATION VV ENTRE 2018 ET 2020 SUR DES POLYGONES DE DEFORESTATION	45
FIGURE 38 : COMPOSITION COLOREE REPRESENTANT LE CHANGEMENT DU COUVERT FORESTIER SUR 3 ANS A L'AIDE DES QUANTILES 10 (B1 : VV 2018, B2 : VV 2019, B3 : VV 2020).....	46

FIGURE 39 : COMPOSITION COLOREE REPRESENTANT LE CHANGEMENT DU COUVERT FORESTIER EN 2019 (B1 : MEDIANE VV, B2 : MEDIANE VH, B3 : ECART-TYPE VH)	46
FIGURE 40 : COMPOSITION COLOREE REPRESENTANT LE CHANGEMENT DU COUVERT FORESTIER EN 2019 (B1 : ECART-TYPE VV, B2 : ECART-TYPE VH, B3 : MEDIANE VH)	47
FIGURE 41 : COMPOSITION COLOREE REPRESENTANT LE CHANGEMENT DU COUVERT FORESTIER EN 2019 (B1 : MOYENNE VH, B2 : Q90 VH, B3 : ECART-TYPE VH)	47
FIGURE 42 : DEFORESTATION COLOREE REPRESENTANT LE CHANGEMENT DU COUVERT FORESTIER EN 2019 (B1 : ECART-TYPE VH, B2 : MEDIANE VH, B3 : Q90 VV)	48
FIGURE 43 : COMPOSITION COLOREE REPRESENTANT LE CHANGEMENT DU COUVERT FORESTIER EN 2019 (B1 : ECART-TYPE VH, B2 : Q90 VH, B3 : MEDIANE VH)	48
FIGURE 44 : DEFORESTATION ANNUELLE ENTRE 2017 ET 2020, MESUREE A L'AIDE DES MOYENNES ANNUELLES EN POLARISATION VV	49
FIGURE 45 : DEFORESTATION ANNUELLE DE 2019 ISSUE D'UNE CLASSIFICATION PAR PIXEL	50
FIGURE 46 : DEFORESTATION TRIMESTRIELLE DE 2019 ISSUE D'UNE CLASSIFICATION PAR PIXEL.....	50
FIGURE 47 : DEFORESTATION AUTOUR DE POKOLA SUR BASE ANNUELLE ENTRE 2017 ET 2020 ISSUE D'UNE CLASSIFICATION PAR PIXEL	51
FIGURE 48 : DEFORESTATION AUTOUR DE POKOLA SUR BASE TRIMESTRIELLE ENTRE 2017 ET 2020 ISSUE D'UNE CLASSIFICATION PAR PIXEL	52
FIGURE 49 : DEFORESTATION AUTOUR DE POKOLA SUR BASE TRIMESTRIELLE ENTRE 2017 ET 2020 ISSUE D'UNE CLASSIFICATION PAR PIXEL OCCULTANT LA DEFORESTATION ANTERIEURE A 2017	53
FIGURE 50 : DEFORESTATION ANNUELLE DE 2019 ISSUE D'UNE CLASSIFICATION PAR OBJET ENTRAINEE PAR DES METRIQUES EN POLARISATION VV	54
FIGURE 51 : DEFORESTATION ANNUELLE DE 2019 ISSUE D'UNE CLASSIFICATION PAR OBJET ENTRAINEE PAR DES METRIQUES EN POLARISATION VH.....	54
FIGURE 52 : DEFORESTATION ANNUELLE DE 2019 ISSUE D'UNE CLASSIFICATION PAR OBJET ENTRAINEE PAR DES METRIQUES EN POLARISATION VV ET VH	54
FIGURE 53 : DEFORESTATION TRIMESTRIELLE DE 2019 ISSUE D'UNE CLASSIFICATION PAR OBJET	55
FIGURE 54 : DEFORESTATION AUTOUR DE POKOLA SUR BASE ANNUELLE ENTRE 2017 ET 2020 ISSUE D'UNE CLASSIFICATION PAR OBJET	55
FIGURE 55 : DEFORESTATION AUTOUR DE POKOLA SUR BASE TRIMESTRIELLE ENTRE 2017 ET 2020 ISSUE D'UNE CLASSIFICATION PAR OBJET	56
FIGURE 56 : PERFORMANCES DES CLASSIFICATIONS PAR PIXEL RAPPORTEES AUX NOMBRES DE PIXELS DE CALIBRATION ET DE VALIDATION	57
FIGURE 57 : PERFORMANCES DES CLASSIFICATIONS PAR PIXEL RAPPORTEES AUX NOMBRES DE POLYGONES DE CALIBRATION ET DE VALIDATION.	57
FIGURE 58 : PERFORMANCES DES CLASSIFICATIONS PAR OBJET RAPPORTEES AUX NOMBRES DE PIXELS DE CALIBRATION ET DE VALIDATION.	57
FIGURE 59 : PERFORMANCE DES CLASSIFICATIONS PAR OBJET RAPPORTEES AUX NOMBRES DE POLYGONES DE CALIBRATION ET DE VALIDATION.	57
FIGURE 60 : PERFORMANCES DES CLASSIFICATIONS TRIMESTRIELLES PAR PIXEL ET PAR OBJET.	59
FIGURE 61 : PERFORMANCES DES CLASSIFICATIONS TRIMESTRIELLES PAR PIXEL ET PAR OBJET, RAPPORTEES AU NOMBRE DE PIXELS DE CALIBRATION ET DE VALIDATION	59
FIGURE 62 : COMPARAISON DES PERFORMANCES DE LA CLASSIFICATION TRIMESTRIELLE DEFORESTATION/NON-DEFORESTATION PAR OBJET ET PAR PIXEL ; (A) CLASSIFICATION PAR OBJET, (B) CLASSIFICATION PAR PIXEL.	63
FIGURE 63 : EFFET DU FILTRAGE SUR LA CLASSIFICATION PAR PIXEL ; (A) CLASSIFICATION PAR PIXEL NON FILTREE, (B) CLASSIFICATION PAR PIXEL FILTREE.	64
FIGURE 64 : EFFET DU FILTRAGE SUR LA CLASSIFICATION PAR OBJET ; (A) CLASSIFICATION PAR OBJET NON FILTREE, (B) CLASSIFICATION PAR OBJET FILTREE.	65
FIGURE 65 : PRODUIT FINAL ISSU DE LA CLASSIFICATION PAR OBJET	67
FIGURE 66 : ANALYSE DU PRODUIT FINI DE LA CLASSIFICATION PAR PIXEL ; (A) DEFORESTATION REELLE IDENTIFIEE, (B) IDENTIFICATION DE DEFORESTATION ERRONEE.	68
FIGURE 67 : PRODUIT FINAL DE LA CLASSIFICATION PAR PIXEL.....	69

Liste des tableaux

TABEAU 1 : MODES DE FONCTIONNEMENT DE S1 (EO OPEN SCIENCE, 2019)	13
TABEAU 2 : PRETRAITEMENTS EFFECTUES SUR LES DONNEES S1 (BAUMANN ET AL. (2018), ERINJERY ET AL. (2018), REICHE ET AL. (2021) ET FORKUOR ET AL. (2020)).....	22
TABEAU 3 : PERFORMANCE DES CLASSIFICATIONS ANNUELLES PAR PIXEL ET PAR OBJET.....	57
TABEAU 4 : PERFORMANCE DES CLASSIFICATIONS TRIMESTRIELLES DE L'ANNEE 2019, PAR PIXEL ET PAR OBJET	58
TABEAU 5 : EXACTITUDE DE L'UTILISATEUR ET DU PRODUCTEUR DES CLASSIFICATIONS ANNUELLES POUR LA DEFORESTATION.....	60
TABEAU 6 : EXACTITUDE DE L'UTILISATEUR ET DU PRODUCTEUR DES CLASSIFICATIONS TRIMESTRIELLES POUR LA DEFORESTATION	60
TABEAU 7 : EXACTITUDE DU PRODUCTEUR DES CLASSIFICATIONS TRIMESTRIELLES PAR OBJET ET PAR PIXEL POUR LA FORET STABLE...	61

Liste des abréviations

ALOS	Advanced Land Observing Satellite
AVHRR	Advanced Very High Resolution Radiometer
CBFP	Congo Basin Forest Partnership
CGLC	Copernicus Global Land Cover
CGLS	Copernicus Global Land Service
CLMS	Copernicus Land Monitoring Service
DEM	Digital Elevation Model
ENL	Equivalent Number of Looks
ESA	European Space Agency
ESRI	Environmental Systems Research Institute
FACET	Forêts d’Afrique Centrale Evaluées par Télédétection
SIG	Système d’Information Géographique
GFW	Global Forest Watch
GRD	Ground Range Detected
ICESat	Ice, Cloud, and land Elevation Satellite)
IW	Interferometric Wide Swath Mode
LAI	Leaf Area Index
LIDAR	Light Detection And Ranging
MLK	Maximum Likelihood Classification
MODIS	Moderate-Resolution Imaging Spectroradiometer
NDVI	Normalized difference vegetation index
OLI	Operational Land Imager
PALSAR	Phased Array L-band Synthetic Aperture Radar
RADD	Radar for Detecting Deforestation
REDD	Reducing Emissions from Deforestation and forest Degradation
RDTC	Range-Doppler Terrain Correction
RDC	République Démocratique du Congo
RF	Random Forest
SAR	Synthetic Aperture Radar
SLC	Single Look Complex
SNAP	Sentinel Application Platform

SRTM	Shuttle Radar Topography Mission
SVM	Support Vector Machine
S1	Sentinel-1
S2	Sentinel-2
TIRS	Thermal Infrared Sensor
TREES	Tropical Ecosystem Environment Observation By Satellites
UFA	Unité Forestière d'Aménagement
UFP	Unités Forestières de Production
VHR	Very High Resolution

Introduction

Les forêts tropicales couvrent 1 770 millions d'hectares, dont 600 millions en Afrique. Elles possèdent de nombreux rôles écologiques vitaux ainsi que des fonctions économiques (Petrrou *et al.*, 2015). Les activités humaines non durables et les catastrophes, naturelles et humaines, telles que les ouragans et les feux de forêt, ont provoqué la perte d'une partie des valeurs écologiques et économiques de ces forêts. En effet, en l'absence de gestion forestière durable, les forêts ne peuvent récupérer la capacité d'assurer pleinement ces rôles écologiques et économiques. (Ngo Bieng *et al.*, 2021)

La recherche scientifique travaille donc depuis de nombreuses années afin de développer des méthodes de suivi et de gestion forestière durable, dans le monde entier (*ibid.*).

Sur ces 600 millions d'hectares de forêt tropicale situés en Afrique, la majorité appartient à la forêt tropicale du bassin du Congo. Afin d'assurer un suivi de la déforestation dans ce grand réservoir de biodiversité, plusieurs pays, y compris le Gabon, le Cameroun, la République centrafricaine, la Guinée équatoriale, la République Démocratique du Congo (RDC) et la République du Congo, se sont associés afin de développer un système de mesure, de signalement et de vérification des changements de couvert forestier (de Wasseige *et al.*, 2014).

Bien que le développement des méthodes de mesure et de signalement de la déforestation progresse, une échelle temporelle de suivi plus précise est cependant nécessaire afin d'établir un programme de détection de la déforestation à haute résolution spatiale et temporelle. En effet, les opérations de déforestation peuvent aussi bien être légales qu'illégales ainsi qu'à petite échelle ou à échelle industrielle. Un suivi global doit donc prendre en compte l'ensemble de ces opérations. (*ibid.*)

Au sein de la République du Congo, la cartographie des forêts tropicales évolue depuis les années 1990 dans le cadre du GSE-FM, qui a pour but de développer une stratégie de réduction des émissions liées à la dégradation et la déforestation (REDD). À l'aide des satellites Landsat-4,-5,-7 et SPOT, entre autres, ce projet a l'ambition de lutter contre le réchauffement climatique provoqué par ces émissions. Les premiers résultats dans le nord du pays ont estimé le taux de déforestation à 0,21 % dans les années 90 et à 0,03 % dans les années 2000 (*ibid.*).

D'autres initiatives de cartographie de la forêt au Congo ont vu le jour depuis, telles que l'atlas des Forêts d'Afrique Centrale Evaluées par Télédétection (FACET), projet qui a pour but de cartographier les forêts du Congo à l'aide des satellites Landsat (*ibid.*).

L'origine de la recherche sur le suivi de la déforestation à l'aide de satellites n'est donc pas récente, mais l'apparition des radars à synthèse d'ouverture (SAR) a permis de développer de nouvelles approches. Ces capteurs permettent de s'affranchir de la couverture nuageuse et donc de produire des résultats indépendants de cette dernière (ESA, 2020).

Ce mémoire va donc poursuivre l'objectif de faire avancer la recherche dans le suivi de la déforestation tropicale à l'aide de Sentinel-1 (S1), le SAR en bande C développé par l'Agence spatiale européenne (ESA), afin de détecter les événements de déforestation, légaux ou illégaux.

Chapitre 1 : Synthèse bibliographique

Cette partie du mémoire va s'articuler en 4 axes. Premièrement, l'étude des impacts environnementaux et socio-économiques de la déforestation dans le monde va être présentée, suivie de l'état des lieux de la forêt tropicale en République du Congo. Ensuite, l'état de l'art de la recherche sur le suivi de la déforestation par télédétection va être dressé, ainsi que celui de la recherche sur l'utilisation des satellites S1 spécifiquement. Enfin, la conclusion de la synthèse bibliographique va permettre d'orienter la méthodologie du mémoire et également, par après, de confronter les résultats du mémoire aux résultats d'études précédemment réalisées.

1) Impacts environnementaux et socio-économiques de la déforestation

La forêt a de multiples fonctions portant sur des aspects écologiques, économiques, sociaux, culturels et environnementaux. Les fonctions environnementales concernent notamment le cycle de l'eau, la régulation du climat, la protection des sols et l'entretien de la biodiversité, faune et flore confondues. En l'absence de forêts, la planète subirait de nombreuses sécheresses, des inondations, de l'érosion des sols et un réchauffement climatique encore plus important. La déforestation impacte la biodiversité par la fragmentation par la route, l'ouverture des canopées, la perte d'espèces et la perte de biomasse. La diminution de ces diverses fonctions a également un impact sur la santé humaine (FAO and UNEP, 2020).

Les forêts hébergent 350 millions de personnes dans le monde et 1,2 milliard d'humains dépendent des forêts comme source de revenus, entre autres dans le cadre de la production agricole (World Bank, 2004). 2 milliards d'humains utilisent la forêt comme moyen de subvenir à leurs besoins fondamentaux comme l'alimentation et le chauffage. La forêt est aussi utilisée comme source d'énergie et représente 7 à 9 % de l'énergie mondiale (Alternatives Sud, 2008).

13 millions d'hectares sont déboisés mondialement chaque année et ces pertes sont inégalement distribuées. Alors qu'une augmentation des surfaces de forêts boréales et tempérées est constatée, la forêt tropicale régresse à un rythme soutenu (*ibid.*).

Le stockage de carbone est l'une des fonctions environnementales vitales des forêts. Celles-ci stockent le carbone dans leur biomasse vivante aérienne et souterraine, dans le bois mort et la litière à la surface du sol, ainsi que dans les sols. Les forêts du monde stockent environ 861 gigatonnes de carbone, dont 50 % dans les forêts tropicales humides. La déforestation menace donc de libérer ce stock et joue donc un rôle néfaste dans le réchauffement climatique (Sasaki *et al.*, 2021).

L'expansion agricole serait la principale cause de déforestation. Les frontières agricoles progressent principalement à cause des paysans recherchant des parcelles à cultiver. Paradoxalement, ce sont eux qui sont affectés en premier par la déforestation, mais ils ne voient pas à long terme et manquent de ressources pour agir autrement. Les autres activités responsables de la déforestation sont principalement l'urbanisation, l'exploitation minière et la collecte de bois de chauffage et d'œuvre (Alternatives Sud, 2008).

Le lien entre pauvreté et déforestation crée un cercle vicieux duquel il est difficile de sortir. En effet, les facteurs contextuels, tels que les politiques agraires et la variation des prix, incitent les personnes dans la précarité à déboiser, mais le déboisement génère des conséquences négatives sur le niveau de vie des populations locales. Un des exemples notables de l'influence de la déforestation sur la pauvreté est l'effet négatif de cette déforestation sur le cycle de l'eau, qui limitera par la suite les capacités de production des sols agricoles (*ibid.*).

2) État des lieux de la forêt tropicale dans la République du Congo

Les forêts de la République du Congo appartiennent au massif forestier du bassin du Congo, qui couvre en majorité la RDC, la Guinée équatoriale, le Cameroun, la République du Congo et le Gabon, formant

le Congo Basin Forest Partnership (CBFP), auxquels se sont joints ensuite d'autres pays pour promouvoir la conservation des forêts (CBFP, consulté le 30/01/2021). Le massif forestier du bassin du Congo représente la deuxième plus grande surface de forêt tropicale au monde, comprenant 8 % des surfaces forestières dans le monde. Le changement de couvert forestier annuel dans la région est estimé à une perte de 0,59 % sur base d'une moyenne effectuée sur la dernière décennie (FAO, 2020).

En 2016, 40 % du couvert forestier était constitué de forêts intactes. Avec un couvert forestier total de 26.6Mha, les forêts tropicales protégées au Congo ne représentent que 11 % de cette surface (2,27Mha). Les forêts non protégées sont dégradées par les routes, les villages et les entreprises d'exploitation et sont donc trop dégradées pour préserver la biodiversité. L'exploitation forestière étant essentielle aux habitants pour subvenir à leur besoin, réduire le nombre d'exploitations n'est pas la solution. Il faut donc étendre la protection aux zones d'exploitation, et s'assurer que la forêt est exploitée de façon durable (*ibid.*).

Dans le cas de la République du Congo, les concessions forestières représentent une surface plus importante que celles des zones protégées (figure 1).

Une gestion durable des exploitations forestières protégeant la biodiversité et les services écosystémiques pourrait donc améliorer la conservation. Les concessions forestières couvrent 79 % des surfaces boisées et c'est donc sur elles que le champ d'action est le plus grand (Global Forest Watch, consulté le 30/01/2021).

Le pays possède 15 zones protégées, notamment les parcs nationaux Odzala-Koukoua, Conkouati-Douli et Nouabalé-Ndoki (*ibid.*).




Figure 1 : Zones protégées et concessions forestières dans la République du Congo

3) État de l'art de la recherche sur le suivi de la déforestation par télédétection

a) Recherche antérieure au 21^e siècle

Les satellites jumeaux S1-A et S1-B ont été lancés respectivement en 2014 et 2016, mais le suivi de la déforestation par télédétection satellitaire existait déjà depuis les années 80. Une synthèse des informations sur les changements rapides d'occupation du sol acquises entre 1981 et 2000 se basant sur 49 jeux de données nationaux ainsi que de télédétection globale, régionale et subrégionale a permis d'évaluer nos connaissances sur les changements de couvert à l'époque (Lepers *et al.*, 2005). Ce type d'étude posait des problèmes, car les résolutions spatiales et temporelles des sources utilisées variaient et n'apportaient donc pas d'information sur la durée du changement ni sur la fréquence des perturbations. De plus, certaines régions du monde étaient mieux couvertes par ces données que d'autres régions, ce qui créait un biais. Cette méthode a permis de mettre en évidence que les changements n'étaient pas aléatoires et qu'ils suivaient une trajectoire en fonction de leur localisation, mais les modifications dans les régions tropicales étaient mal documentées.

D'autres études ont affiné la résolution spatiale. L'article de Lambin et Ehrlich (1997) a permis de repérer les hotspots de déforestation dans les tropiques, à l'aide de données du Radiomètre Avancé à Très Haute Résolution (AVHRR) de résolution spatiale d'1km dans le cadre du projet TREES (Tropical Ecosystem Environment Observation by Satellites). Ce projet avait pour but de réaliser un inventaire des surfaces forestières, de mettre en place un réseau de surveillance forestière et enfin d'extraire des informations spatio-temporelles sur les modèles de déforestation (Malingreau *et al.*, 1995).

AVHRR est un instrument fournissant des données entre 4 et 6 bandes spectrales, en fonction du satellite portant l'instrument, et sa résolution spatiale est de 1,1km (Earth Resources Observation And Science (EROS) Center, 2017).

Les hotspots de déforestation entre les tropiques ne peuvent être analysés qu'à fine échelle spatiale, mais les modèles de déforestation à grande échelle présentent des informations générales qui ne peuvent apporter de pouvoir explicatif et prédictif, mais peuvent tout de même générer des informations globales. C'est pourquoi ces 2 échelles peuvent être liées en échantillonnant des données à haute résolution spatiale et en les généralisant à l'échelle globale afin d'apporter des informations sur le changement de couvert forestier, non seulement générales, mais également précises.

Les proportions de couverts forestiers ont pu être extraites du projet TREES, dont les surfaces couvertes entre 35 et 80 % de forêts ainsi que les zones fragmentées ont été définies comme les hotspots de déforestation.

Les cartes présentant une grande probabilité de déforestation en fonction d'indicateurs statiques, tels que les proportions de couverts forestiers et les aspects socio-économiques, ont été superposées dans un Système d'Information Géographique (SIG), auquel on a alors appliqué des variations paramétriques pour améliorer l'identification des hotspots.

Ainsi, des cartes présentant les lieux à haut risque de déforestation en fonction de maximum 4 variables, qui changeaient de nature à chaque nouvelle production de carte, ont été produites afin de déterminer quels critères affectaient le plus la déforestation et quels lieux étaient les hotspots de déforestation.

Moins de 10 % des surfaces étudiées ont été identifiées comme tels. La méthode fut également appliquée à des changements des attributs de surface tels que la température de surface et les indices de végétation d'une série temporelle sur 10 ans. Cette méthode permet d'analyser la déforestation dans une approche multidimensionnelle, mais manque de précision spatiale et temporelle. Dans le cadre d'un suivi de la déforestation régionale, la méthode reste à valider avec des données de télédétection.

b) Suivi des changements d'occupation du sol à l'aide des satellites Landsat

Différentes études se sont depuis appuyées sur des images satellites pour déterminer les changements de couvert forestier. Les satellites américains du programme Landsat ont fourni des données qui ont été exploitées dans de nombreuses études portant sur le sujet de la déforestation. Lancé pour la première fois en 1972 avec Landsat-1, le programme a envoyé au total 7 satellites entre 1972 et 1999, avec un huitième lancé en 2013. Ce dernier possède 2 instruments, le « Operational Land Imager » (OLI) et le « Thermal Infrared Sensor » (TIRS), qui fournissent des images dans 11 bandes spectrales au total, du visible à l'infrarouge, et qui augmentent sa précision radiométrique et sa performance contre le bruit par rapport aux générations de satellites précédentes. La résolution des images varie entre 15 et 100m en fonction des bandes spectrales. Le satellite a une périodicité de 99 minutes et un cycle de répétition orbitale de 16 jours (USGS, 2016). Un neuvième satellite est prévu d'être lancé en 2021.

Parmi de nombreuses études, les méthodes de Duveiller *et al.* (2008) et Mikwa *et al.* (2016) permettant d'étudier les changements d'occupation du sol avec les données des satellites Landsat peuvent être mises en évidence. La première fut réalisée en Afrique centrale tandis que la seconde fut réalisée dans la région forestière de Kisangani en RDC. La première méthode s'appuie sur l'utilisation de l'image satellitaire la plus récente pour déterminer le couvert forestier, puis la compare avec une image prise précédemment. Si un changement se produit entre ces deux dates, la trajectoire du changement doit être identifiée et la superficie du changement doit être mesurée. Le taux de changement annuel est ensuite calculé en rapportant le changement d'occupation du sol entre ces 2 dates au changement historique total, généralement calculé sur 10 ans. Les images segmentées sont interprétées automatiquement puis visuellement afin de limiter l'impact de la variabilité au sein et entre les échantillons, causée par la diversité de l'occupation du sol et les variations radiométriques et atmosphériques.

Les échantillons de validation de la première méthode sont ensuite classifiés de manière non supervisée et par photo-interprétation. Les images sont ainsi classées en 4 catégories : non utilisables, sans changement, sans changement, mais avec différentes occupations du sol (on calcule alors l'étendue de la forêt) ou avec un changement. L'exactitude générale de la discrimination de couvert forestier/non forestier est de 93 % pour 100 échantillons. Les erreurs de classification proviennent de mauvaises interprétations dues à la subjectivité de l'interprétation. Ce ne sont donc pas des erreurs dans la chaîne de production et la méthode en elle-même est donc efficace pour différencier les couverts forestiers des non-forestiers. Afin d'appliquer cette méthode très efficace à d'autres régions tropicales, il faut ajouter des observations optiques ou des SAR afin de se libérer de la contrainte de la couverture nuageuse (Duveiller *et al.*, 2008).

La seconde méthode mise en évidence et utilisant les données Landsat combine les bandes panchromatiques pour produire une composition colorée qui est ensuite classifiée de manière non supervisée. La classification est évaluée par une matrice de confusion et le changement d'occupation du sol est analysé à travers une matrice de transition. L'étude produit finalement un taux annuel de déforestation pour la région, mais cela ne donne qu'une tendance et, tout comme la méthode précédente, ne nous permet pas d'étudier les zones sous couvert nuageux (Mikwa *et al.*, 2016). L'exactitude générale est, comme dans l'article précédent, de 93 % pour les données de l'année 2001.

Une troisième méthode (Kranz *et al.*, 2018) utilise les données Landsat de la RDC en 2 échelles, régionale et locale. Une classification par objets pour l'échelle locale et par pixels pour l'échelle régionale et une reclassification sémantique permettent de créer des classes de forêt primaire, forêt secondaire/agriculture et buissons/agriculture. Le prétraitement des données consiste en un empilement de couches, comme dans la méthodologie de Mikwa *et al.* (2016), ainsi qu'en un traitement des images pour s'affranchir des pixels nuageux qui sont inutilisables. La méthode permet de déterminer la présence de forêt primaire avec une exactitude générale entre 90,48 % et 94,39 %, mais l'ombre nuageuse n'est pas toujours entièrement retirée avec l'algorithme Fmask. L'utilisation de S1 permettrait de s'affranchir de l'inexactitude liée à l'ombre nuageuse ainsi que de toute

contrainte atmosphérique, et de lier les phénomènes de déforestation au contexte socio-économique régional, comme le mentionnait Lambin et Ehrlich (1997).

Combinant des données du « Moderate-Resolution Imaging Spectroradiometer » (MODIS), de Landsat et des données de contribution spontanée, le programme Global Forest Watch (GFW) est une initiative du World Resources Institute (WRI) ayant pour objectif de quantifier les pertes globales de couvert forestier (Zhang *et al.*, 2020). Avec plus de 2 millions d'utilisateurs, cette plateforme libre d'accès s'associe avec plus de 100 organisations, dont Google et l'Institut de recherche sur les systèmes environnementaux (ESRI), pour développer des outils fournissant des informations sur les changements forestiers à de nombreux projets et recherches (WRI, consulté le 05/06/2021).

Le MODIS est un système d'imagerie composé d'une série d'instruments d'observation qui fournissent des images dans 36 bandes spectrales avec une résolution spatiale variant entre 250m et 1 km. Le système fait le tour de la terre en 1 ou 2 jours et fournit donc des images de moins bonne résolution, mais plus fréquentes que les systèmes vus précédemment. Sa limitation principale est donc sa résolution spatiale (NASA, 2020).

c) Combinaison des images issues de différentes missions satellitaires

Certaines études se sont penchées sur la possibilité de combiner les images issues de différentes missions satellitaires afin d'étudier la déforestation dans les tropiques.

Le système S1 est une constellation de 2 satellites équipés d'un SAR en bande C lancés par l'ESA en 2014. Le système peut imager la terre entière en 6 jours avec une résolution spatiale pouvant atteindre 5m. Les satellites disposent d'un système de transmission de données par laser qui permet de transférer les données aux stations terrestres de façon continue (ESA, 2020).

Le système Sentinel-2 (S2) est un ensemble de satellites à imagerie optique. Les images sont fournies en 13 bandes spectrales, du visible au moyen infrarouge, notamment dans le red-edge qui est une portion du spectre électromagnétique dont la réflectance permet de mettre en évidence l'activité végétale. Les données S2 ont une largeur au sol de 290km par fauchée et une résolution spatiale de 10 à 60m en fonction des bandes spectrales utilisées. Le système fournit des images de la terre entière tous les 5 jours (ESA, 2020).

« Advanced Land Observing Satellite » (ALOS) est un satellite de télédétection japonais lancé en 2006 et dont la mission s'est terminée en 2011. Il est équipé de 3 instruments : PRISM, un capteur optique panchromatique, AVNIR-2, un capteur optique infrarouge et « Phased Array L-band Synthetic Aperture Radar » (PALSAR). Avec un cycle de répétition de 46 jours, il fournit des images moins fréquemment que les systèmes vus précédemment, mais est plus complet puisqu'il possède 3 instruments. PALSAR possède une résolution spatiale entre 10 et 100m en fonction de ses modes d'utilisation (fin, ScanSAR ou polarimétrique) et fonctionne en bande L, contrairement aux satellites S1 qui fonctionnent en bande C (Jaxa, 2020).

L'utilisation de plusieurs capteurs, en l'occurrence les capteurs optiques et le SAR, augmente la résolution spatiale et temporelle de la détection de la déforestation. Si le SAR possède une profondeur de pénétration plus faible et est rapidement saturé par le signal sur les forêts, il possède également une fréquence d'échantillonnage plus importante et permet donc un suivi plus systématique que l'utilisation de données optiques seules. Cependant, il faut soustraire la saisonnalité forestière lors du traitement des données au risque d'effectuer de fausses détections (Hamunyela *et al.*, 2020). Par saisonnalité forestière, on entend les variations climatiques, mais également phénologiques interannuelles. En effet, les feuilles produites à la fin de la saison des pluies ont des capacités photosynthétiques et une efficacité d'utilisation de l'eau supérieures à celles des feuilles produites au début de la saison des pluies, donnant lieu à des valeurs de réflectance variables au cours d'une année (Kitajima *et al.*, 1997). La plupart des approches par séries temporelles proposent un ajustement du modèle à la saisonnalité. Cela nécessite un historique d'observations suffisant, ce qui est rarement

possible avec Landsat à cause de la couverture nuageuse. En combinant les données Landsat aux séries temporelles dont les données ont été acquises par PALSAR-2 ainsi qu'aux données S1, on peut effectuer une normalisation temporelle plus efficace que l'ajustement par saisonnalité pour suivre la déforestation (Reiche *et al.*, 2018a). Hamunyela *et al.* (2020) propose également une normalisation spatiale de chaque pixel avec son entourage pour être affranchi de la saisonnalité. Cette normalisation peut être appliquée aux séries temporelles créées à l'aide des données SAR, acquises par S1 et ALOS.

Reiche *et al.* (2018a) effectue donc une normalisation des séries temporelles des données SAR S1 et PALSAR-2, combinées aux séries temporelles des données optiques Landsat. On obtient avec cette méthode une exactitude générale de 99,8 % avec une détection des événements de déforestation d'une exactitude de 88 % pour l'utilisateur et de 89 % pour le producteur. L'exactitude générale issue de la combinaison des capteurs est supérieure à celle issue de l'exploitation des capteurs individuels. Dans le cadre du suivi de la déforestation en temps réel, des compromis doivent être réalisés entre une haute résolution spatiale et une haute résolution temporelle. Le choix se fera en fonction de l'utilisation souhaitée.

Une seconde approche multispectrale avec Landsat-8 et S1 produit un modèle continu à 30m de résolution avec une exactitude élevée pour l'identification du couvert forestier (R^2 de 0,85 et une erreur quadratique moyenne de 4,4 %). La double polarisation (VV and VH) de S1 augmente la capacité de détection (Baumann *et al.*, 2018 ; Reiche *et al.*, 2018a), mais les données S1 seules produisent une moins bonne performance (R^2 de 0,31 et erreur quadratique moyenne de 21 %) que lorsqu'elles sont combinées aux données Landsat-8. Ces résultats sont à analyser avec précaution, car les deux modèles de prédiction varient en fonction de la région. De plus, les échantillons entraînant le modèle proviennent d'Amérique du Sud. Le modèle est donc efficace uniquement pour certains milieux spécifiques.

La cartographie du couvert forestier à l'aide de Landsat et S1 a été initialement créée afin de surmonter les limites du MODIS et du AVHRR, dont les produits à grande échelle ont une résolution spatiale trop grossière pour être utilisés dans le cadre du suivi des changements de couvert forestier (Baumann *et al.*, 2018).

Les images composites de Landsat et S1 permettent de mesurer la réflectance et la rétrodiffusion sur une longue période et captent donc la phénologie et les effets du climat sur la végétation (Baumann *et al.*, 2018).

Une étude (Li *et al.*, 2020) couplant les données de l'instrument « Light Detection And Ranging » (LIDAR), fournies par le satellite ICESat-2 (Ice, Cloud, and land Elevation Satellite), un satellite de la NASA muni de 2 instruments de mesure dont la mission s'est terminée en 2010 (NASA, 2013), aux données S1, S2 et Landsat-8 permet d'étudier l'empreinte carbone en mesurant la canopée. Les performances des classifications issues de l'algorithme Random Forest (RF) et entraînées par les données S1 et S2 étaient meilleures que les performances des classifications entraînées par Landsat-8. Les données S1 et S2 ont produit une classification avec une exactitude générale de 58 % tandis que les données Landsat ont produit une classification avec une exactitude de 46 %. Les données S1 et S2 performent donc légèrement mieux que les données Landsat. La combinaison des coefficients de rétrodiffusion de S1 et des variables red-edge de S2 présente des perspectives prometteuses dans l'étude de l'empreinte carbone.

Une étude de la diversité des espèces végétales et de la structure des forêts tropicales fragmentées propose deux méthodes de suivi. La première consiste en un inventaire de terrain, à l'aide de surfaces de 20X50m. Cette méthode est la plus précise pour estimer les essences des espèces et leur structure, mais demande beaucoup de main d'œuvre. La seconde est basée sur la télédétection, idéalement à l'aide d'imagerie aérienne telle que LIDAR ou par imagerie satellite, idéalement issue de S2, si l'imagerie aérienne est trop chère. Une interpolation est ensuite effectuée sur base de quelques parcelles. Les variations spatiales et temporelles créent une grande incertitude, mais la méthode est

applicable à grande échelle. L'auteur considère que les 2 méthodes devraient être complémentaires (Ganivet and Bloomberg, 2019).

d) Combinaison des satellites S1 et S2

La littérature scientifique est riche en articles présentant des méthodologies de suivi de l'occupation du sol combinant les données S1 et S2. Deux études sur la savane ont combiné ces satellites (Forkuor *et al.*, 2020 ; Zhang *et al.*, 2019). La première utilise des métriques mensuelles moyennées à l'année afin d'identifier la biomasse au-dessus du sol. Cette méthode permet de combiner les bandes red-edge de S2, les indices de végétation, dont l'Indice de Végétation par Différence Normalisée (NDVI), et la bande C de S1 dont le potentiel d'analyse de la biomasse n'a pas encore été exploré en détail, contrairement aux bandes P et L d'autres SAR. À la suite de l'extraction et du traitement des données de rétrodiffusion et des données spectrales, une analyse de régression est réalisée à l'aide de l'algorithme RF. L'exactitude est ensuite évaluée et une carte de la distribution de la végétation est produite. L'analyse des résultats indique que S2 est plus efficace pour modéliser la biomasse, mais certains articles démontrent le contraire (Navarro *et al.*, 2019).

L'utilisation des données S1 pour modéliser la biomasse pose problème, car la bande C a une longueur d'onde courte, ce qui génère une capacité limitée à pénétrer dans la canopée, à l'inverse des bandes L et P. Une autre explication de la contre-performance de la modélisation issue des données S1 est l'exclusion des informations sur la texture dans la liste des indicateurs du modèle. Les données S1 modélisent mieux la biomasse que les données S2 quand les informations de texture contribuent au modèle. La sensibilité du modèle peut également augmenter en diminuant la résolution temporelle. La conclusion de l'étude est que la combinaison des données S1 (en saison des pluies) et S2 (en saison sèche) produit un meilleur suivi du changement de l'occupation du sol que les données séparées (Forkuor *et al.*, 2020).

La seconde étude sur le changement de l'occupation du sol dans la savane utilise une machine à vecteurs de support (SVM) pour classifier la présence ou l'absence de canopée boisée avec des données S1 et S2 à une résolution spatiale de 10m. La méthode produit des résultats d'une exactitude générale de 93 %. Les résultats sont donc meilleurs en combinant les 2 types de satellites. Les données issues des satellites ne donnent qu'une estimation du couvert et leur fiabilité est insuffisante pour en tirer des conclusions. Des observations de terrain ou des images à très haute résolution (VHR) ainsi que des images aériennes LIDAR peuvent également être exploitées, mais les données sont chères et l'application de la méthode est difficile à effectuer à l'échelle régionale et continentale, donc peu adéquate pour les études des surfaces boisées fractionnées, celles-ci étant réalisées à haute résolution spatiale.

Une classification combinant les données S1 et S2 est comparée à celles obtenues avec les données MODIS, avec le Copernicus Global Land Cover (CGLC), l'un des produits du Copernicus Global Land Service (CGLS), ainsi qu'avec les résultats d'autres études. La comparaison indique que les surfaces boisées sont surestimées avec les données S1 ou S2, et que seule la combinaison des deux satellites donne une bonne approximation de la surface boisée. La classification est alors validée avec des images VHR (1mx1m) et cette validation produit une exactitude générale de 89 % (Zhang *et al.*, 2019).

En ce qui concerne les zones humides et tropicales, d'autres études ont évalué les performances de S1 et S2 pour classifier les types de végétation. Afin d'analyser l'influence du red-edge, un SVM produit une classification sur base des données S1 et S2. L'erreur de la classification est ensuite mesurée à l'échelle d'un pixel avant de produire une matrice de confusion. Les résultats indiquent que la combinaison des satellites S2 et S1 génère une exactitude générale plus élevée que les données S2 seules, respectivement 94 % et 92 %. Il est important de noter que l'article ne classe pas uniquement la forêt, mais aussi l'eau, les buissons, les affleurements de calcaire, et d'autres couverts (Kaplan and Avdan, 2019).

Erinjery *et al.* (2018) a analysé le potentiel des données S1 et S2 pour identifier les types de végétation dans les forêts tropicales indiennes. Les données de terrain étant difficiles à obtenir à cause de leur difficulté d'accessibilité, de la difficulté du travail de terrain, de larges surfaces à couvrir et l'acquisition de ces données consommant du temps et de la main d'œuvre, l'auteur suggère de les extrapoler avec des méthodes de télédétection afin de suivre les changements forestiers dans ces grandes régions isolées.

Les classifications entraînées par des données de NDVI, des données de texture et des données des bandes combinées des différents capteurs produisent toutes des exactitudes générales supérieures à 75 % (*ibid.*).

Des études ont montré que le SAR fournit des informations précises sur l'occupation du sol et améliore les classifications lorsqu'il est combiné à d'autres données optiques multispectrales. Le SAR est habituellement moins précis que l'optique pour la même résolution spatiale, mais il est suffisamment précis pour suppléer les données optiques des régions avec une grosse couverture nuageuse (Kwarteng *et al.*, 2008), et permet alors d'atteindre une exactitude générale de 80 %. Dès l'apparition du 1^{er} satellite en bande L JERS-1, il était clair que la grande longueur d'onde discrimine les types de végétation plus précisément que la bande C de S1.

Deux algorithmes de classification ont été utilisés par Erinjery *et al.* (2018) : la classification de maximum de vraisemblance (MLK) et RF. La MLK est plus précise, excepté pour les données NDVI et les données de texture pour lesquelles RF est plus précis. Les résultats de l'étude produisent une exactitude globale de 85,9 %.

La conclusion de l'étude est que la combinaison des satellites permet d'améliorer l'exactitude des classifications et que les données de texture peuvent compenser la perte de données liée à la couverture nuageuse (*ibid.*).

L'exactitude des classifications de végétation combinant les données des satellites S1 et S2 est donc plus élevée que l'exactitude des classifications entraînées par les données d'un seul satellite pour Forkuor *et al.* (2020), Zhang *et al.* (2019), Kaplan et Avdan (2019) et Erinjery *et al.* (2018).

4) La recherche sur l'utilisation des satellites S1 pour le suivi de la déforestation

Malgré leur courte longueur d'onde, l'exploitation des données des satellites S1 possède beaucoup de potentiel, car ils fournissent des observations gratuites et libres d'accès, dans une longueur d'onde non impactée par les conditions atmosphériques. Ces satellites ont été utilisés dans l'étude de l'utilisation du sol et du couvert végétal en Amazonie (Nicolau *et al.*, 2021), dans le développement du Copernicus Land Monitoring Service (CLMS) (Atzberger *et al.*, 2020) ainsi que dans l'estimation de la quantité de biomasses au Vietnam (Van Pham *et al.*, 2019), dans l'étude du changement forestier en Roumanie (Tanase *et al.*, 2019) et dans bien d'autres applications.

L'étude de Nicolau *et al.* (2021) a révélé que les signaux de la bande C de S1 ont une pénétration faible qui empêche le faisceau radar de pénétrer complètement dans la structure plus dense et stratifiée de la canopée, comme mentionné dans l'article de Reiche *et al.* (2018a) et ci-dessus.

S1 permet de surveiller la phénologie des forêts décidues grâce à sa résolution spatiale et temporelle élevée (Frison *et al.*, 2018) et permet également de mettre en évidence l'émergence et la chute des feuilles par une variation de la rétrodiffusion (Rüetschi *et al.*, 2017), mais ces fonctionnalités sont peu pertinentes dans l'étude des forêts tropicales. En ce qui concerne le suivi de l'exploitation illégale du bois, l'étude conclut que l'utilisation du SAR n'est pas suffisante pour la représenter, car son exactitude générale est de 80 % et qu'il faudrait donc combiner le SAR à un capteur optique (Atzberger *et al.*, 2020).

L'interférométrie du SAR (InSAR) peut être utilisée pour classifier les occupations du sol. Elle nécessite au minimum 2 acquisitions pour extraire des données sur la cohérence, définie entre autres par le déphasage entre 2 acquisitions. Les séries temporelles créées à partir des données de cohérence doivent donc idéalement avoir des intervalles d'acquisition d'un mois ou moins, afin de conserver l'information. La dégradation des données peut être corrigée à l'aide de la fonction « reduced stack size ». La comparaison de la modélisation utilisant un traitement « Single Look Complex » (SLC), basé sur la rétrodiffusion et celle utilisant un traitement InSAR montre que ces modèles produisent des exactitudes similaires, mais que la méthode InSAR est plus précise pour la classification des forêts et des surfaces artificialisées. La combinaison des variables d'interférométrie et de rétrodiffusion produit les résultats les plus précis (91 %) pour la classification des sols (Atzberger et al., 2020 ; Rüetschi et al., 2017 ; Frison et al., 2018).

L'analyse de la source des variations de la cohérence et de la rétrodiffusion pour différentes polarisations et l'étude sur de plus longues durées permettrait de mieux saisir les tendances caractéristiques des classes qui montrent un comportement saisonnier. L'amélioration de la résolution de la carte résultant de la méthodologie et l'augmentation du nombre d'échantillons entraînant le modèle permettrait la discrimination d'un plus grand nombre de classes. Il serait également intéressant d'augmenter le nombre de données et de tester les limitations de la cartographie à grande échelle (Sica et al., 2019).

Des simulations électromagnétiques ont montré des sensibilités différentes au contenu en eau dans la végétation, au Leaf Area Index (LAI) et aux perturbations dans la forêt en fonction de la bande SAR (Tanase et al., 2019).

La bande C est influencée par le volume foliaire et est utile pour surveiller la perte de feuille. Cependant, la bande ne peut pas être utilisée pour mesurer la sécheresse. Les petits impacts forestiers tels que l'exploitation forestière à petite échelle et l'affinage ne sont pas facilement repérables avec les bandes C et L. La bande P leur est préférée pour cette application (*ibid.*).

Actuellement, les limitations du SAR sont l'utilisation d'une seule fréquence, l'intervalle entre deux acquisitions et la géométrie. Pour dépasser ces limites, il serait intéressant de densifier les séries temporelles et de combiner le SAR à des capteurs passifs, optiques ou thermiques, et actifs, radar ou LIDAR. Les capteurs actifs compensent les limitations des capteurs passifs. L'interprétation des capteurs optiques est intuitive pour la surveillance des forêts, mais ils sont limités par la couverture nuageuse et l'angle d'illumination solaire (*ibid.*).

Les nouvelles techniques d'observation des forêts avec le SAR sont sensibles aux changements de structure forestière grâce à leur résolution temporelle et spatiale élevée (image jusqu'à tous les 3 jours), leur polarisation, leur angle d'incidence plus élevé et leurs informations orbitales précises. Ces techniques apportent donc une solution à plusieurs limitations des produits générés par le passé (*ibid.*).

Dans une étude datant de 2020 (Hoekman et al., 2020), le suivi de la déforestation en presque temps réel à l'aide de données S1 fut étudié dans les forêts tropicales. La détection de dégradations localisées est retardée de plusieurs semaines dues à l'humidité du sol avec les données S1, tandis que les données S2 fournissent des retards de détection de plusieurs mois à cause de la couverture nuageuse. L'auteur précise que la rétrodiffusion naturelle due à l'humidité et au type forestier doit être prise en compte, ainsi que la durée des changements, l'angle d'incidence et la rétrodiffusion de zones nues, éléments spécifiques à l'utilisation de S1. Le contraste forêt/non forêt est souvent faible en bande C et la variabilité spatio-temporelle des forêts peut être élevée. Les changements forestiers subtils ne sont pas faciles à détecter et sont souvent rapidement perdus à cause de la rapidité de repousse de la végétation. Les dégradations subtiles sont donc plus facilement détectables avec des données optiques, comme mentionnées dans l'article de Forkuor et al. (2020).

Une étude récente sur l'utilisation de S1 dans le bassin du Congo (Reiche *et al.*, 2021) a permis de mettre en place un système d'alerte en cas de perturbation forestière. Ce produit à haute résolution spatiale et temporelle produit un suivi forestier presque en temps réel. En récoltant des images entre janvier 2019 et juillet 2020, l'auteur de l'étude a relevé 4 millions de perturbations forestières, principalement de taille réduite, c'est-à-dire inférieure à 0,5 hectare. Google Earth Engine a fourni les images en polarisation alternée (VV et VH), de type « Ground Range Detected » (GRD) et en orbite ascendante et descendante. Les images prétraitées par les outils de l'ESA ont d'abord été normalisées à l'aide de la rétrodiffusion moyenne sur base d'anciennes métriques avant d'être classées pixel par pixel en fonction de la probabilité que leur couvert soit de la forêt, avec une résolution spatiale de 10m. Un algorithme de détection de perturbations forestières est ensuite créé afin de déterminer la probabilité qu'un pixel de forêt soit perturbé, les pixels avec la plus haute probabilité de perturbation étant considérés comme appartenant à l'alerte. Les résultats sont ensuite validés à l'aide d'images optiques S2. Des variations de perturbations peuvent être constatées entre les différents pays du bassin du Congo, en fonction des saisons et des variations climatiques. Cette méthode fournit selon les auteurs une exactitude pour l'utilisateur et le producteur respectivement de 97,6 % et 95 % et est plus efficace pour repérer les événements de déforestation que les systèmes d'alerte basés sur des images Landsat. Les conditions de l'étude étant semblable au sujet de ce mémoire et les résultats étant spectaculaires, la méthodologie utilisée pourrait être le point de départ à un approfondissement dans le cadre spécifique du suivi de la déforestation.

Ce système d'alerte de perturbations forestières est désormais en application dans le cadre des systèmes d'alerte GFW et Radar for Detecting Deforestation (RADD) (Wildenborg, 2021).

5) Description du satellite S1

Le système S1 est une constellation de 2 satellites équipés d'un SAR en bande C lancé par l'ESA à partir de 2014. Le radar peut pénétrer à travers la couverture nuageuse, ce qui permet à S1 de fournir des observations sans lacunes pour les régions tropicales. Les observations sont fournies au niveau global tous les 6 à 12 jours avec une résolution spatiale de 10m. La longueur d'onde des SAR est plus longue que dans l'optique et le radar fonctionne à l'aide de transmission de vagues électromagnétiques à travers l'atmosphère. De plus, il est monostatique, ce qui signifie qu'il utilise la même antenne pour émettre et recevoir les signaux (EO Open Science, 2019).

S1 est un radar à impulsion en orbite héliosynchrone, proche des pôles et à 698km de la surface de la Terre. Il met 90 minutes pour faire le tour de la terre. Le satellite a un cycle de répétition de 12 jours pour chaque satellite jumeau. Pour la constellation, l'intervalle de répétition est donc de 6 jours. Avec les orbites ascendantes et descendantes, le temps de revisite est de 3 jours dans certaines régions. À proximité des pôles, les orbites se superposent et l'intervalle de répétition atteint alors 1 jour et demi. En ce qui concerne le Congo, le temps de retour est de 12 jours selon la figure 2. Le temps de vie minimal du satellite est de 7 ans et le temps de vie objectif est de 12 ans, mais le programme *Copernicus* prévoit de remplacer ces satellites par d'autres satellites identiques pour assurer la continuité (*ibid.*).




Figure 2 : Intervalle de revisite de S1 dans le monde (EO Open Science, 2019)

Les informations fournies par le satellite sont contenues dans le rayonnement électromagnétique. Le spectre électromagnétique varie en fonction du type d'occupation du sol, chaque sol ayant une signature spectrale propre. Le signal est composé de 3 contributions :

- Le volume, correspondant à l'interaction entre l'occupation du sol et le signal radar
- La surface, correspondant à l'interaction entre le sol et le radar
- Les interactions entre le volume et la surface.

Ces 3 contributions varient notamment en fonction de la rugosité liée à la structure du sol, de la texture et de l'humidité. Les variations topographiques de la structure et l'angle d'incidence du rayonnement peuvent causer des distorsions des distances et également influencer les contributions au signal (*ibid.*).

Le radar mesure l'amplitude et la phase du signal électromagnétique. L'amplitude varie en fonction des propriétés de la cible, tandis que la phase est une fonction de la distance entre le capteur et sa cible ainsi que des propriétés de la cible. La bande C de S1 possède une fréquence moyenne de 5 405 GHz et une longueur de 5cm. Les données sont acquises en 2 coordonnées : azimuth et range, cette dernière correspondant à la distance du satellite au sol. L'angle d'incidence de S1 varie entre 29,1° et 46°, et influence les propriétés radiométriques de l'image résultante, tout comme la longueur d'onde, la fréquence et la polarisation (*ibid.*).

Les produits de S1 peuvent être sous forme de SLC ou de GRD. L'interférométrie permet d'interpréter les données complexes SLC en superposant les images les unes sur les autres pour identifier des changements d'un pixel à l'autre. Les images S1 possèdent un aspect tacheté (speckle) qui peut être retiré à l'aide de l'interférométrie. Les informations contenues dans les images S1 peuvent ainsi être lues (*ibid.*).

Dans le tableau 1, on peut consulter les différents modes de fonctionnement de S1 pour acquérir des données. Le mode de fonctionnement le plus récurrent dans la littérature mentionnée dans cette revue est le IW (*ibid.*).

	Résolution du produit GRD	Largeur de bande	Polarisation
Extra Wide Swath Mode (EW)	50m	>400km	HH + HV ou VV + VH
Interferometric Wide Swath Mode (IW)	10 ou 20m	>250km	HH + HV ou VV + VH
Stripmap Mode (SM)	9m	>80 km	HH + HV ou VV + VH
Wave Mode (WM)	50m	20 x 20 km ² avec un espacement de 100km	HH ou VV

Tableau 1 : Modes de fonctionnement de S1 (EO Open Science, 2019)

Les opérations d'acquisition de données de S1 fonctionnent actuellement à presque pleine capacité. Il est donc difficile d'ajouter des observations additionnelles aux missions de routine, mais on peut tout de même obtenir des données en urgence ou pour supporter la recherche sur l'activité volcanique, les ouragans, etc. S1 acquiert actuellement 13TB de données par jour. Le contrôle de l'exactitude radiométrique est effectué à l'aide de sites de contrôle, et permet de constater que l'exactitude est très bonne. Elle pourrait être encore améliorée avec des corrections de terrain (*ibid.*).

La structure et la taille des surfaces étudiées ont un grand impact sur la capacité de détection en bande C, particulièrement sensible au volume foliaire. Les dégradations forestières subtiles ne sont pas facilement repérables avec les bandes C et L quand l'acquisition d'images est unique ou rare. La longueur d'onde P est plus efficace, mais sa durée de vie réduite, la revisite bisannuelle et la faible résolution spatiale (60m) limitent son utilité. Des recherches supplémentaires sont nécessaires pour surmonter les limitations de la bande C en ce qui concerne les changements forestiers sur de petites surfaces en exploitant des séries temporelles plus denses et en acquérant des images sur les orbites ascendantes et descendantes. On pourrait également combiner les multifréquences P, L et C pour repérer les changements forestiers plus subtils ainsi que combiner le SAR à un capteur passif pour surveiller et caractériser plus efficacement les changements forestiers (*ibid.*).

Notons néanmoins que S1 ne possède qu'une bande C et que c'est donc cette bande qui sera utilisée dans la méthodologie de ce mémoire, mais il est intéressant de noter que les autres bandes du SAR ont des capacités de détection spécifiques différentes (*ibid.*).

6) Conclusion

La revue des articles scientifiques étudiant le suivi de la déforestation à l'aide de différents satellites nous a permis de constater que différents types de satellites et leur imagerie avaient été utilisés pour suivre l'évolution du couvert forestier. On constate que la cartographie forestière à large échelle, telle que réalisée par le projet TREES par exemple, fournit des informations importantes dans le cadre de la gestion forestière, mais n'est pas adaptées au suivi de la déforestation à haute résolution, comme la déforestation sporadique le long des routes.

Certaines études montrent que les méthodologies exploitant les données fournies par les satellites Landsat produisent des classifications d'occupation du sol ayant une exactitude générale de 93 % pour 2 études et entre 90 et 94 % pour la dernière.

En ce qui concerne l'utilisation combinée des satellites Landsat et S1, on obtient un coefficient de performance, représentant l'exactitude générale de la classification, de 0,85. En combinant les satellites S1, ALOS-2 PALSAR-2 et Landsat, l'exactitude générale atteint 98 %, ce qui est une performance particulièrement élevée, mais ces résultats correspondent à des zones d'étude en Amérique du Sud et rien ne garantit que les performances seraient similaires pour le bassin du Congo.

La combinaison du LIDAR aux satellites Landsat produit un coefficient de performance de 0,46 tandis que celle du LIDAR à S2 produit un coefficient de 0,58. De nouveau, l'étude en question a été réalisée en Mongolie et ne produirait donc probablement pas les mêmes résultats dans le bassin du Congo.

Les études combinant les satellites S1 et S2 produisent des résultats ayant des exactitudes générales variant entre 85,9 % et 94 %, en fonction des méthodes appliquées et des zones d'études sélectionnées. Les protocoles expérimentaux combinant ces deux satellites produisent donc des résultats ayant des exactitudes générales élevées.

Les classifications des occupations du sol à l'aide de S1 ont jusqu'à présent produit des résultats avec des exactitudes variant entre 80 % et 91 % en fonction des méthodologies utilisées.

Étant donné que la zone d'étude de ce mémoire se situe au Congo et que les données sont acquises à l'aide des satellites S1 uniquement, l'objectif serait d'atteindre pour des zones à fort couvert nuageux des résultats produisant une exactitude similaire à d'autres études réalisées dans des conditions plus favorables.

Un élément récurrent dans les études mentionnées dans cette synthèse bibliographique est la nécessité d'effectuer des compromis entre les résolutions spatiales et temporelles dans le suivi de la déforestation. Le choix de ces compromis est réalisé en fonction de l'objectif à atteindre.

Chapitre 2 : Objectifs

Le bassin du Congo représente la deuxième plus grande surface forestière tropicale au monde, après l'Amazonie. Les forêts denses humides couvrent 36 % de l'Afrique centrale et y jouent différents rôles. Ces zones servent de réservoirs de biodiversité, mais aussi de régulateur du climat et remplissent également des rôles alimentaires, sociaux, culturels et économiques pour les populations qui y vivent. Il est donc vital de conserver ces zones forestières et de contrôler le processus de déforestation (COMIFAC, 2015).

Les images satellites ont permis d'améliorer le suivi de la déforestation en temps réel et différents systèmes ont été développés au fil des années. Les systèmes d'observations optiques ne peuvent donc pas repérer tous les changements du couvert forestier en raison de la couverture nuageuse. L'utilisation des données S1 pourrait résoudre ces limitations puisque ce satellite fonctionne à l'aide d'un SAR qui permet d'obtenir des images malgré la couverture nuageuse. S1 a donc une fréquence d'échantillonnage plus importante et plus constante que les instruments optiques puisque l'acquisition des données est indépendante des conditions nuageuses, de la saison et de la position du soleil.

L'utilisation de S1 au Congo présente un désavantage : la résolution temporelle est de 12 jours et n'est donc pas suffisante pour déterminer le moment exact d'un événement de déforestation. Actuellement, on détermine la date d'occurrence d'un événement en considérant qu'il s'est produit durant la période séparant la prise de 2 images. Cependant, une gestion forestière efficace nécessite des résolutions spatiale et temporelle élevées. Il faut donc développer une méthodologie permettant d'utiliser S1 pour repérer les événements de déforestation aux résolutions spatiales et temporelles les plus élevées possible.

Le choix de la zone d'étude s'est porté sur le bassin du Congo, car les surfaces déforestées y sont plus petites qu'en Amazonie et sont donc bien plus difficiles à mettre en évidence. La zone est donc idéale pour développer un système de suivi de la déforestation à haute résolution spatiale. La République du Congo est un pays intéressant, car le phénomène de déforestation y est très présent. De nombreuses régions peuvent donc servir de cas d'études. De plus, la cartographie de la végétation dans ce pays est avancée, ce qui permettra une validation aisée des résultats. Au sein du pays, on s'intéresse particulièrement aux zones de déforestation non gérées puisqu'il s'agit des zones les plus problématiques.

L'objectif de ce mémoire est donc de développer et d'évaluer une méthodologie permettant de détecter les événements de déforestation à l'aide de données S1, ce qui permettrait de suivre le phénomène de déforestation indépendamment de la couverture nuageuse et avec des résolutions temporelle et spatiale élevées. Basé sur S1, l'objectif est plus particulièrement d'explorer l'information contenue dans le signal d'amplitude et de cohérence des séries temporelles disponibles, ce dernier étant rarement étudié.


Chapitre 3 : Matériel et méthodes

Ce chapitre s'articule en 3 parties. La 1^{re} présente la zone d'étude et la seconde porte sur le matériel utilisé, c'est-à-dire les images, leur acquisition et le prétraitement auquel ces images ont été soumises. La troisième partie présente la méthodologie développée et appliquée aux images prétraitées, comprenant les traitements statistiques, les algorithmes de classification et l'affichage optimal des résultats.

La zone d'étude est localisée à Pokola et s'étend du point de coordonnées 1°48'10" N, 15°55'46"E au nord-ouest à celui de coordonnées 16°21'13"E, 1°21'41"N au sud-est.

La zone d'étude se situe en République du Congo et plus spécifiquement dans l'Unité Forestière d'Aménagement UFA) de Pokola, localisée dans le district de Ouessou, au sein du département de la Sangha. Cette zone d'étude comprend la ville de Pokola, siège de la CIB, et s'étend au nord-ouest jusqu'à l'agglomération de Ouessou.

Le choix de zone d'étude a été réalisé sur base d'une observation du taux de changement du couvert forestier à travers le bassin du Congo à l'aide de GWF. La zone qui semblait subir les changements les plus fréquents entre 2019 et 2020 était la zone aux alentours de l'agglomération de Pokola. La perte de couvert forestier entre 2000 et 2017 dans Pokola, représentée à la figure 3, confirme le choix de zone d'étude. En effet, on voit que la zone a subi une déforestation intense depuis les années 2000 et correspond à une zone intéressante à analyser dans le cadre de ce mémoire.



1) Contexte socio-économique

Pokola est situé sur la rive gauche de la rivière Sangha, à environ 30 kilomètres au sud d'Ouesso. C'est le siège de la CIB (Congolaise industrielle des bois) et c'est aussi l'une de ses 3 principales concessions, avec Kabo et Loundougou.

La ville a subi une expansion démographique rapide au cours des dernières décennies, sa population étant passée de 300 habitants dans les années 60 à plus de 11 000 en 1990 et à plus de 20 000 aujourd'hui. La ville accueille aujourd'hui des milliers d'employés de la CIB. Cette expansion démographique entraîne également une urbanisation croissante dans la région, ce qui constitue l'une des principales menaces pour la forêt de la région, par conversion de surfaces forestières en surfaces agricoles autour des agglomérations (OPITCONGOBRAZZAVILLE, 2017).

Le rôle de la CIB est d'assurer une exploitation forestière durable, notamment par la conservation de la biodiversité et le contrôle de la chasse. Le parc national Nouabalé-Ndoki reste, par exemple, un refuge de biodiversité tout en appartenant aux concessions de la CIB (Clark C.J. and Poulsen J.R., 2014).

Depuis 2002, la CIB a créé l'UFA de Pokola (figure 4), sur une surface de 452 200 ha. Le plan d'aménagement de l'UFA propose différentes mesures de gestion de la production et de l'exploitation des forêts afin d'assurer une gestion durable. Le plan d'aménagement propose également des mesures de protection et de conservation de la faune, ainsi que des mesures sociales. L'UFA se concentre sur l'exploitation de 5 essences (Sapelli, Sipo, Bilinga, Kosipo et Ayous) qui représentent la majeure partie du volume exploité. Les principaux types de formations végétales qu'on retrouve sur l'UFA sont les forêts mixtes de terre ferme, les forêts limbali, les forêts inondables et les cultures (République du Congo : Ministère de l'Économie Forestière et du Développement Durable, OLAM, CIB, 2006).




Figure 4 : UFA de Pokola (source : OLAM, 2016)

Conjointement à l'UFA, différentes Unités Forestières de Production (UFP) ont été créées afin d'assurer une rotation dans la série de production. Chaque UFP possède un volume d'exploitation objectif et la mise en exploitation dure 5 ans. La figure 5 présente la localisation et le découpage des UFP au niveau de l'UFA Pokola (OLAM, 2016), la zone d'étude s'étendant sur les UFP 2 et 3.




Figure 5 : Unités Forestières de Production de l'UFA Pokola (OLAM, 2016)

L'économie de la République du Congo est principalement liée à l'exploitation forestière. Pokola étant le siège de la CIB, l'économie du village tourne presque exclusivement autour de ce secteur (de Wasseige *et al*, 2014). Malgré l'expansion démographique et économique de Pokola de ces dernières 50 années, le volume total d'arbres abattus sur la concession forestière diminue depuis 2005, comme on peut le voir dans la figure 6 (OFAC, consulté le 15/02/2021).




Figure 6 : Volume total de production de bois sur la concession forestière de Pokola (OFAC, consulté en 2021)

2) Climat

Le climat du Congo est de type équatorial congolais. Il présente deux saisons humides et deux saisons sèches. La première saison sèche, la plus longue, s'étend de décembre à fin février. La seconde, plus courte, s'étend de fin juin à août (Suspense *et al.*, 2019). La zone d'étude est dominée par la forêt tropicale humide qui couvre plus ou moins 90 % du district de la Sangha (Deutscher *et al.*, 2017).

La pluviométrie moyenne annuelle dans la région est de 1686 mm, et comprend 2 pics en mai et en octobre, qui atteignent en moyenne de 200 à 240mm par mois (République du Congo : Ministère de l'Économie Forestière et du Développement Durable, OLAM, CIB, 2006).

La figure 7 illustre plus précisément les variations de précipitations et de température mensuelles.




Figure 7 : Diagramme ombrothermique de Pokola (Climate-Data, consulté en 2021)

3) Topographie

Le relief de l'UFA Pokola possède une altitude moyenne d'environ 350 mètres et l'UFA est entièrement située sur le bassin hydrographique de la Sangha. À l'aide de données issues de la « Shuttle Radar Topography Mission » (SRTM), ayant une résolution de 30m (Rodríguez *et al.*, 2006), on constate sur la figure 8 que le relief de la zone d'étude varie entre une altitude de 302m et de 516m. Cette variation topographique est due à la présence de la rivière Sangha qui traverse la zone d'étude et donc à la présence d'ondulations topographiques des sous-bassins versants.




Figure 8 : Topographie de la zone d'étude

4) Sources de données

a) Acquisition et prétraitement des données d'amplitude

Les données ont été acquises par le satellite S1-A, depuis l'orbite descendante relative 7, selon le mode IW, sur la période du 11/01/2017 au 21/12/2020. 224 images furent ainsi acquises sur 112 dates, dans la polarisation VV et dans la polarisation VH. Bien que la polarisation croisée (VH et HV) soit plus informative au niveau volumétrique pour la structure des arbres que la co-polarisation, seule la polarisation à bande unique VV dispose d'une base de données temporelle suffisante pour résoudre les profils saisonniers des données de rétrodiffusion sur de très grandes surfaces, la polarisation croisée présentant un large délai entre les mesures (Zhang *et al.*, 2019). Ces données sont accessibles sur la plateforme *Copernicus* en SLC, un format de données prétraitées. Les données SLC contiennent les informations originales sur l'amplitude et la phase capturées par le SAR, ainsi qu'une correction sur la position (latitude et longitude) du satellite.

Les données ont ensuite été prétraitées via Sentinel Application Platform (SNAP), interface permettant de réaliser une série d'opérations successives sur les images :

Correction orbitale	Précision sur l'orbitale à l'aide de la position du satellite et de sa vitesse recalculée a posteriori, en éliminant l'erreur liée à la différence de phase, selon la formule suivante $\Delta\varphi = \frac{4\pi}{\lambda} [\Delta R_{err}]$ Ou $\Delta\varphi$ = la variation de la phase interférométrique ΔR_{err} = l'erreur sur l'orbite issue du mouvement du satellite et du changement d'angle de vue (Mancon <i>et al.</i> , 2015)
Calibration radiométrique	Conversion des données brutes en mesures quantitatives interprétables (σ^0) (<i>Calibrage radiométrique Sentinel-1—ArcGIS Pro Documentation</i> , no date)
Correction du bruit d'origine thermique	Suppression de l'erreur radiométrique due à la modification de température du capteur et de l'émissivité de la terre (<i>Suppression de bruit thermique Sentinel-1—ArcGIS Pro Documentation</i> , no date)
Correction de terrain Range-Doppler (RDTC)	Correction de l'influence du relief sur l'intensité de rétrodiffusion, effectuée à l'aide d'un « Digital Elevation Model » (DEM) de résolution 30m formé par des données SRTM (Loew and Mauser, 2007)
Filtre spatial	Filtre permettant de réduire l'effet poivre et sel

Tableau 2 : Prétraitements effectués sur les données S1 (Baumann *et al.* (2018), Erinjery *et al.* (2018), Reiche *et al.* (2021) et Forkuor *et al.* (2020))

En outre, une correction de pente est effectuée, mais n'est pas indispensable dans ce cas-ci puisque la zone d'étude présente des pentes inférieures à 6 % sur la plupart de sa surface et qu'aucune pente ne dépasse 13 %. Le produit issu de cette correction est normalisé en γ^0 mais étant donné que le terrain présente des pentes relativement faibles (figure 9), sa valeur est proche d'un coefficient de rétrodiffusion σ^0 . Les polarisations VV et VH de rétrodiffusion sont extraites à une résolution de 10m.

Il est important de noter que les mesures présentées ici ainsi que celles de l'ensemble des mesures d'amplitude présentées dans ce mémoire sont en décibels.

À ces prétraitements doit être ajouté le « geocoding », qui permet de convertir les informations spatiales reçues des images en coordonnées pour les images de cohérence.




Figure 9 : Répartition spatiale des pentes sur la zone d'étude

Certaines conditions climatiques, notamment des intempéries, causant des erreurs de prétraitement ou des erreurs dans le signal, peuvent générer des artefacts rendant une image inutilisable. Sur la figure 10, certains artefacts issus de ces images sont illustrés.




Figure 10 : Plages d'artefacts contenues dans l'image S1 obtenue le 15/11/2020, liées probablement à des orages locaux

b) Acquisition et prétraitement des données de cohérence

La cohérence est une mesure de la similarité entre deux passages de satellites S1 (Nasirzadehdizaji *et al.*, 2021). Les valeurs de cohérences devraient donc être élevées en cas de déforestation, le changement d'occupation du sol occasionnant une forte variation entre 2 acquisitions.

224 images de cohérences ont également été calculées à partir des images acquises du 11/01/2017 au 21/12/2020 par le satellite S1-A, sous la forme SLC, selon le mode IW et en polarisation VV et VH. La correction orbitale et la correction de terrain sont identiques à celles appliquées aux images d'amplitudes.

L'utilisation de la cohérence dans le cadre du suivi de la déforestation étant peu explorée dans la littérature scientifique, le potentiel des résultats à extraire de ces données reste à étudier dans le cadre de ce mémoire.

5) Méthodologie d'analyse des séries temporelles

La revue de la littérature scientifique présentée précédemment permet d'identifier la méthodologie à suivre afin d'atteindre les objectifs mentionnés au chapitre précédent.

Reiche *et al.* (2021) propose une méthode de normalisation des données produisant des résultats efficaces pour identifier la perturbation forestière à 0,2 ha. Cet article a permis d'initier la méthodologie de ce mémoire, cette méthode de normalisation étant compatible avec le suivi de la déforestation. La chaîne de traitement proposée est discutée à la figure 11.

Le développement de la méthodologie a ensuite abouti à une cartographie des événements de déforestation, sur une période de 4 ans et à une résolution temporelle de 90 jours.




Figure 11 : Organigramme présentant la méthodologie de suivi de la déforestation à l'aide de données S1

a) Analyse préalable des résolutions spatiales de 10m et 20m

Pour s'assurer que la résolution spatiale à 10m est nécessaire, une analyse préalable de la perte d'information liée au passage à une résolution à 20m est réalisée. Une segmentation à 20m de résolution est ainsi produite et sera associée à des polygones de déforestation identifiés à 10m pour observer si les zones de déforestation de taille réduite sont également identifiées à 20m. La

segmentation à 20m est réalisée avec les mêmes paramètres que ceux de la segmentation à 10m présentée au point g), afin de permettre la comparaison.

b) Calcul de métriques

Le traitement des séries temporelles prétraitées de cohérence et d'amplitude débute par le calcul de différentes métriques. Reiche *et al.* (2021) propose le calcul de la médiane et de l'écart-type (STD) de produits GRD pour l'orbite ascendante et descendante sur 2 ans, avec un total de 5300 images. Les produits GRD ont une résolution spatiale, c'est-à-dire la mesure de la capacité du système à distinguer les cibles adjacentes, de 20m et un espacement de pixel, c'est-à-dire la distance entre les pixels adjacents dans une image, de 10m. Les images prétraitées par les outils de l'ESA ont d'abord été normalisées à l'aide de la rétrodiffusion moyenne sur base d'anciennes métriques avant d'être classées pixel par pixel en fonction de la probabilité que leur couvert soit de la forêt, avec une résolution spatiale de 10m.

Afin d'adapter le calcul des métriques à cette étude, certaines modifications ont été apportées à la méthode. Seule l'orbite descendante, survolant la zone tous les 12 jours à 4 h 42, sera exploitée, car la zone n'est pas couverte par l'orbite ascendante.

Ainsi, les métriques annuelles, trimestrielles et semestrielles de la médiane, de l'écart-type, mais également de la moyenne et des quantiles 10 et 90 vont être produites, afin de fournir des informations supplémentaires à celles fournies par la médiane et l'écart-type. Le quantile 10 et le quantile 90 représentent les 10 % de valeurs extrêmes sur la période sélectionnée, respectivement les 10 % inférieurs et supérieurs de l'ensemble des données de la période. Le calcul est effectué pour l'amplitude et la cohérence, dans les polarisations VV et VH, ainsi que leur ratio, soit 3 séries temporelles distinctes.

c) Normalisation

La normalisation permet de confronter chaque image et chaque métrique à l'historique des 4 années, selon la formule suivante :

$$X_{\text{normalisé}} = \frac{X - \mu}{\sigma}$$

Équation 1 : Normalisation des images et des métriques

Où X est l'image ou la métrique qu'on souhaite normaliser, μ est la médiane calculée pour l'ensemble des pixels de chaque image des 4 années étudiées et σ l'écart-type des pixels de chaque image des 4 années étudiées.

Cette normalisation permet de limiter les artefacts causés par les effets saisonniers, de centrer le signal et d'accentuer les informations de changement forestier apportées par les métriques.

L'ensemble des métriques et des images d'amplitude et de cohérence est ainsi normalisé.

d) Analyse de la qualité du signal

La variabilité du signal normalisé de chaque acquisition entre 2017 et 2020 nous permet d'identifier les artefacts. Le signal d'amplitude étant sensible à la pente, la rugosité et l'humidité du sol, il peut varier d'une image à l'autre pour des raisons autres que le changement de couvert forestier. Afin d'analyser le signal de rétrodiffusion issu du satellite et d'identifier de potentiels artefacts périodiques, une série d'échantillons sont prélevés sur 3 types de surfaces stables : l'eau, les surfaces artificialisées et les surfaces bâties.

La figure 12 présente les polygones de surface stable utilisés pour analyser la variabilité du signal non liée à la surface.




Figure 12 : Sélection de polygones de surface stable utilisés pour analyser le bruit du signal de rétrodiffusion

e) Métriques des séries temporelles

Les données issues du calcul de ces métriques peuvent être interprétées sous forme de séries temporelles afin d'obtenir des informations sur le comportement de ces métriques. Reiche *et al.* (2021) réalise les séries temporelles sur base de moyennes annuelles, de 2019 à 2020. Dans le cas de ce mémoire, les séries temporelles seront réalisées sur l'ensemble des métriques calculées précédemment, ainsi que sur différentes périodes.

La cohérence interférométrique se calculant entre 2 acquisitions d'images, l'information de cohérence moyennée sur plusieurs images risque d'être moins précise que celle moyennée sur 2 acquisitions.

La figure 13 représente un exemple de série temporelle, illustrant l'évolution semestrielle des médianes de rétrodiffusion, sur 6 échantillons de déforestation.




Figure 13 : Évolution du signal des médianes semestrielles normalisées en polarisation VV entre 2018 et 2020 sur des polygones de forêt dégradée

Pour ce faire, des polygones de forêt stable et des polygones de déforestation sont tracés et la moyenne des valeurs au sein de ces polygones est extraite pour chaque métrique. Les polygones utilisés pour construire les séries temporelles peuvent être visualisés sur la figure 14. Les polygones de forêt stables sont identiques pour chaque période, tandis que les polygones de déforestation changent en fonction de la période étudiée, c'est pourquoi ils sont plus nombreux.




Figure 14 : Polygones de forêt stable et de déforestation utilisés pour construire les séries temporelles

f) Sélection des variables les plus informatives

Dans cette partie de la méthodologie, les métriques, considérées jusqu'à présent d'un point de vue, conceptuel sont présentées.

Les métriques dont le comportement illustre le mieux les périodes de déforestation sur les séries temporelles présentées ci-dessus sont ensuite combinées sous forme de compositions colorées annuelles. Ces compositions sont formées de manière à illustrer le plus clairement possible le changement de couvert qui s'est déroulé sur l'année, et de façon à mettre en évidence les différentes textures témoignant d'un changement de couvert afin d'identifier les zones déforestées et d'apprécier qualitativement les métriques ainsi créées.

Les métriques sont traitées à l'aide d'un filtre médian (figure 15) réattribuant à chaque pixel la valeur médiane de son voisinage. Ce filtre permet de réduire le bruit sans contaminer les valeurs voisines avec le bruit (à l'inverse d'une moyenne), de s'affranchir de la saisonnalité et d'extraire uniquement les informations de changement de couvert forestier (Hamunyela *et al.*, 2020).




Figure 15 : Illustration du filtre médian appliqué aux métriques




Figure 16 : Composition colorée de métriques annuelles représentant le changement du couvert forestier en 2020 (B1 : moyenne VH, B2 : médiane VH, B3 : écart-type VH)

La figure 16 présente un exemple de composition colorée, témoignant du changement de couvert autour de Pokola sur l'année 2019.

g) Classification

Pour la dernière étape de la méthodologie inspirée de l'article de Reiche *et al.* (2021), les métriques significatives sont exploitées dans le cadre d'une classification. Reiche *et al.* (2021) propose une méthodologie dans laquelle les probabilités d'être ou non un pixel de forêt sont déterminées à l'aide d'un modèle gaussien, définissant les surfaces non forestières comme étant celles dont la valeur de la métrique vaut 4σ , σ étant l'écart-type des séries temporelles de 2017 et 2018. Chaque nouvelle observation est donc soumise à cet algorithme afin de déterminer la probabilité de chaque pixel d'être

déforesté (Reiche *et al.*, 2015). La figure 17 présente la courbe gaussienne sur base de laquelle les probabilités d’être déforesté sont déterminées.




Figure 17 : Courbe gaussienne représentant les probabilités d’être une surface forestière, selon la méthode de Reiche *et al.* (2015) (Epsilon Theory, consulté le 06/06/2021)

Contrairement à ce que préconise l’article, la méthodologie du mémoire va s’orienter vers une classification supervisée en Machine Learning. Le choix de l’algorithme de classification s’est porté sur RF, car il semble produire de meilleurs résultats dans le cadre du suivi de la déforestation (Atzberger *et al.*, 2020).

Ainsi, des échantillons de déforestation vont être délimités sous forme de polygones, simultanément pour une année et pour chaque trimestre de cette année. Ces polygones permettront ainsi d’effectuer une classification en deux temps : d’abord une classification pour chaque année, ensuite une classification pour chaque trimestre. Les polygones de déforestation ont été tracés sur la bordure entre la forêt et la zone de déforestation, puis une zone tampon intérieure (buffer) de 10m a systématiquement été appliquée sur chaque polygone afin d’éviter la contamination des résultats par des pixels de bordure. Sur la figure 18 sont présentés les différents polygones exploités dans la méthodologie, dont la date de déforestation a également été déterminée par année puis par trimestre.




Figure 18 : Polygones de forêt stable et de déforestation utilisés pour entraîner les classifications

Le fond de carte est une composition colorée mettant en évidence les zones de déforestation. Les polygones de déforestation se situent pour la plupart dans les zones mauves, qui représentent les zones déforestées durant l'année 2019. La vignette supérieure droite représente des polygones de forêts stables ripicoles, bordant les rivières, dont la signature spectrale est similaire à celle des zones déforestées et qui doivent donc être calibrées en tant que forêt stable afin d'entraîner le modèle correctement.

Classification par pixel

Dans la classification par pixel, chaque pixel est classé individuellement en fonction de l'information spectrale qu'il contient. Les informations spectrales apportées ici concernent les métriques significatives identifiées précédemment. Les données d'entraînements sont déterminées selon la méthode présentée au point « Attribution d'une fonction aux polygones de forêt stable et de déforestation ».

Classification par objet

La classification par segmentation, ou classification par objet, regroupe les pixels en clusters homogènes. L'outil utilisé ici pour effectuer cette segmentation multirésolution est le logiciel *ecognition developer 10*. Cet outil crée des objets sur base de paramètres d'homogénéité spectrale et spatiale. Les paramètres de segmentation sont les suivants :

- Paramètre d'échelle : 3
- Indice de forme : 0,6
- Indice de compacité : 0,2

Le paramètre d'échelle est particulièrement faible, afin de segmenter précisément les zones de déforestation restreintes. Les indices de forme et de compacité ont été déterminés par essais-erreur. On donne une valeur basse au critère de compacité, les forêts ne représentant pas des formes compactes, et une valeur élevée à l'indice de forme, afin que les couleurs n'influencent pas trop le résultat.

Les données sur base desquels la segmentation est effectuée sont l'ensemble des métriques annuelles de 2019, c'est-à-dire médiane, moyenne, écart-type et quantiles, pour la cohérence et l'amplitude, selon les polarisations VV et VH, ainsi que le ratio de ces polarisations.

Chaque segment de la zone d'étude se voit ensuite attribuer la valeur moyenne des métriques de rétrodiffusion en polarisation VV au sein de ce segment, afin d'entraîner par la suite la classification.

Attribution d'une fonction aux polygones de forêt stable et de déforestation

Les polygones présentés ci-dessus vont se voir attribuer une fonction de calibration ou de validation, pour les 2 types de classification. Ainsi, les polygones de moins de 3 ou de 3 pixels sont éliminés, les polygones de moins de 10 pixels ou de 10 pixels deviennent des polygones de validation et les polygones de plus de 10 pixels sont répartis de manière aléatoire selon les proportions de 75 % pour la calibration et 25 % pour la validation.

h) Validation

La validation des résultats obtenus lors des classifications est réalisée à l'aide des polygones définis précédemment comme étant les polygones de validation. Ces échantillons de déforestation et de forêt stable seront comparés à la classe que leur aura attribuée la classification.

Les validations des classifications par pixels sont indépendantes des validations des classifications par objet.

Les résultats de ces validations sont présentés sous forme de matrices de confusion, desquels seront extraites des exactitudes générales, ainsi que des exactitudes de producteur et d'utilisateur.

L'exactitude de l'utilisateur est calculée en divisant le nombre total de classifications correctes pour une classe particulière par le total des pixels classifiés comme appartenant à cette même classe.

L'exactitude du producteur est calculée en divisant le nombre de pixels de validation correctement identifiés pour une classe particulière par le total des pixels de validation pour cette classe.

Afin d'assurer la cohérence des résultats de la validation, il faudra s'assurer que les nombres de pixels validés dans chaque classe sont égaux.

Chapitre 4 : Résultats et interprétation

Ce chapitre présente les résultats obtenus à la suite de la mise en place de la méthodologie ainsi que leur interprétation.

a) Analyse préalable des résolutions spatiales de 10m et 20m

La superposition de la segmentation à 20m de résolution aux polygones de déforestation et à une composition colorée mettant en évidence la déforestation (figure 17) illustre l'importance de la résolution spatiale. En effet, on peut constater que les polygones issus de la segmentation à 20m ne mettent pas toutes les zones déforestées en évidence. Certaines tâches bleutées illustrant le changement de couvert sont situées dans des segments comprenant majoritairement de la forêt stable. De ce fait, elles risquent donc d'être occultées lors d'une discrimination de couvert forestier/non-forestier.




Figure 19 : Segmentation à 20m de résolution spatiale sur une composition colorée de 10m de résolution ; (A) Polygone segmenté correctement à 20m de résolution, (B) Polygone segmenté largement à 20m de résolution, (C) Polygone segmenté correctement à 10m de résolution.

La segmentation à 20m de résolution permet d'identifier les zones de déforestation large (vignette A), mais pas les zones de taille réduite (vignette B). À l'inverse, la segmentation à 10m de résolution permet de former des segments adaptés à la déforestation des zones de grandes tailles, comme de petites tailles (vignette C).

Les paramètres de segmentation sont les mêmes que ceux évoqués au chapitre précédent.


b) Calcul de métriques

Amplitude

L'intérêt de la résolution spatiale de 10m étant avéré, seules les métriques calculées sur base des images à 10m de résolution seront utilisées dans la suite de l'étude.

Les périodes sur lesquels les métriques sont calculées n'impactent pas visuellement la représentation des métriques. Ainsi, une même métrique annuelle, semestrielle ou trimestrielle présente un contenu très similaire aux métriques calculées sur les autres périodes.

La polarisation permet d'extraire différentes mesures de la rétrodiffusion. On remarque que les polarisations VV et VH mettent en évidence différentes textures, tandis que le ratio de ces polarisations représente des pixels isolés et tachetés. On peut donc estimer que ces polarisations apporteront des informations distinctes (figure 20).



Data source : Sentinel-1 images (2019)

Figure 20 : Représentation des q10 annuels de 2019 dans les 3 polarisations sous la forme d'une composition colorée ; (R) Polarisation VV, (B) Polarisation VH, (G) Ratio VV/VH.

Les moyennes et médianes trimestrielles sont visuellement similaires. Généralement, plus le nombre de valeurs sur lequel les moyennes et médianes sont calculées est grand, plus ces 2 métriques seront similaires, les médianes étant néanmoins moins sensibles aux valeurs extrêmes. Ces deux métriques adoptent donc un comportement similaire sur de longues périodes.

Les quantiles mettent en évidence certaines zones dans la périphérie de Pokola et de Ouesso (une agglomération au nord-ouest du périmètre d'étude) qui sont probablement des zones de déforestation. Les quantiles semblent donc être de bonnes métriques pour le suivi de la déforestation.

Ils expriment les valeurs extrêmes du signal sur une période, ces valeurs extrêmes représentant un changement de couvert du sol.

Enfin, l'écart-type est la métrique présentant le profil le plus contrasté, mettant en évidence les régions dans lesquelles le couvert varie au cours d'une période déterminée. Il semble ainsi être également une métrique à exploiter dans le cadre de cette étude.

Cohérence

La cohérence représentant la variation de la phase du signal d'une mesure à l'autre, les métriques annuelles, semestrielles et trimestrielles démontrent un important effet poivre et sel dû à la perte d'information causée par la métrique temporelle. Les métriques annuelles, semestrielles et trimestrielles sont entièrement bruitées dans chaque polarisation et chaque type de métrique.

La cohérence ne sera donc pas exploitée visuellement, notamment dans les compositions colorées présentées au point f), mais possède de l'information d'une date à l'autre et sera donc exploitée dans les séries temporelles au point e) et dans les classifications au point g).

c) Normalisation

La normalisation permet de lisser le signal des différentes métriques en diminuant le bruit. La figure 21 présente l'effet de la normalisation sur la moyenne du signal de 2019 en polarisation VV. Les métriques issues de la normalisation présentent un profil plus constant, étant affranchies de l'effet du relief sur la valeur des pixels. De plus, la division par l'écart-type a multiplié les valeurs par un facteur 100. La gamme de valeurs des données normalisées est donc plus étendue.




Figure 21 : Effet de la normalisation sur la valeur des pixels de la moyenne annuelle de 2019 en polarisation VV

La normalisation permet également de centrer le signal des métriques sur 0 et d'éliminer le biais du signal (figure 23). Cela amène donc un effet important sur les valeurs des métriques.




Figure 22 : Évolution du signal des médianes trimestrielles en polarisation VV entre 2018 et 2020 sur des polygones de forêt stable




Figure 23 : Évolution du signal des médianes trimestrielles normalisées en polarisation VV entre 2018 et 2020 sur des polygones de forêt stable

L'effet positif de la normalisation étant avéré, c'est désormais avec les métriques normalisées que les analyses suivantes seront réalisées.

d) Analyse de la qualité du signal

La figure 21 présente les valeurs du signal de rétrodiffusion en polarisation VV rétrodiffusé sur des surfaces planes pour une période de 4 ans. Pour chaque polygone, la moyenne du signal de l'ensemble des pixels est calculée. Ce graphique permet de constater que le signal varie en fonction de la nature de ces surfaces. On constate également que le signal rétrodiffusé par les surfaces construites est le plus stable. On peut donc en déduire que le signal subit peu de perturbations liées aux conditions climatiques et topographiques. Les analyses effectuées par la suite seront donc affranchies de toute perturbation sur le signal brut.

Le signal rétrodiffusé par les surfaces artificialisées varie plus que celui rétrodiffusé sur les surfaces stables, ce qui s'explique par la présence de végétation ou d'eau sur ces surfaces. La variation reste inférieure à l'écart-type, dont l'ordre de grandeur est de 100, et n'est donc pas significative.

Le signal est principalement affecté par la présence d'eau. En effet, on peut constater que les surfaces telles que la rivière, mais également des zones d'inondations renvoient un signal plus bruité que les autres types de surfaces. Lorsque le signal est bas, les surfaces d'eau provoquent une réflexion spéculaire menant à un coefficient de rétrodiffusion très faible. En ce qui concerne les pics de signal, aucune périodicité stable n'est relevée dans le signal. Les variations dans le signal ne peuvent donc pas être expliquées par des variations saisonnières. Des intempéries peuvent quant à elles expliquer en partie les variations. Les hypervariabilités, d'une date à l'autre, visibles sur la série temporelle sont caractéristiques d'intempéries ponctuelles. Cette hypothèse est confirmée par l'analyse du climat aux dates présentant une grande variation de signal. Ces dates présentent en effet un climat pluvieux et orageux, ce qui explique les variations de signal (IMERG, 2019).

Ces variations peuvent également être expliquées par le vent qui augmente la rugosité de l'eau, ainsi que par des éléments de surface situés sur la rivière, et également des éléments en suspension dans la rivière, qui peuvent créer des interférences.

En ce qui concerne les surfaces bâties, ces dernières rétrodiffusent le signal le plus stable dont la valeur est systématiquement inférieure à l'écart-type des séries temporelles de rétrodiffusion sur 4 ans. Ce sont les surfaces dont le signal est le moins affecté par l'eau et la végétation. On peut donc en déduire que le signal de rétrodiffusion brut ne subit pas de perturbations.

Le signal de rétrodiffusion dans la polarisation VH est quant à lui moins stable sur l'ensemble des surfaces, ce qui est cohérent avec le comportement attendu du signal en polarisation VH. En effet, l'émission et la réception du signal se font respectivement verticalement et horizontalement, contrairement au signal en polarisation VV qui est émis et réceptionné verticalement et qui ne dépend pas des propriétés de dépolarisation des surfaces. Le graphe représentant les variations du signal en polarisation VH peut être consulté en annexe 1.

Les polygones de surfaces d'eau, de surfaces bâties et de surfaces artificialisées ont respectivement en moyenne une superficie de 24 ha, de 0,09 ha et de 0,39ha. Les grandes superficies rétrodiffusent en général un signal plus stable que les superficies réduites. L'analyse des superficies des polygones renforce les observations énoncées ci-dessus, car les grandes surfaces d'eau rétrodiffusent un signal variable et les petites surfaces artificialisées et bâties rétrodiffusent un signal stable. En rapportant les signaux à la même surface, on constate que les surfaces bâties et artificialisées rétrodiffusent un signal encore plus stable.




Figure 24 : Évolution du signal moyen de rétrodiffusion en polarisation VV sur des surfaces stables sur une période de 4 ans

e) Métriques des séries temporelles

Les métriques annuelles, semestrielles et trimestrielles de chaque statistique présentent des tendances similaires face au changement d'occupation du sol. Cependant, le signal des métriques trimestrielles présente des tendances plus marquées et des variations de signal plus importantes lors d'un changement de sol. Ainsi, en fonction du type de coupe et de repousse forestière, le signal des métriques présente différents profils. Les écarts-types ayant été utilisés comme dénominateur dans le calcul de la normalisation, leur signal reste plat et n'est donc pas représentatif du comportement de la métrique.

➤ Moyennes

Les moyennes trimestrielles en polarisation VH illustrent la période de déforestation par une baisse de signal (figure 25). La polarisation VV illustre également la déforestation, mais semble plus bruitée étant donné que les moyennes des échantillons 1, 2 et 3 présentent un pic dans le signal. Elle illustre également une redescende immédiate qui ne correspondent à aucun changement de couvert (figure 26). Ce pic pourrait correspondre à une repousse de la canopée supérieure, indétectable visuellement.

La chute de signal au premier trimestre de 2020 semble correspondre à une recoupe du couvert herbacé. Les images d'optique confirment la coupe au 1^{er} trimestre de 2020. La polarisation VH, traduisant les effets de dépolarisation et plus liée à la rétrodiffusion volumétrique, porte des informations moins bruitées.




Figure 25 : Évolution du signal des moyennes trimestrielles normalisées en polarisation VH entre 2018 et 2020 sur des polygones de déforestation




Figure 26 : Évolution du signal des moyennes trimestrielles normalisées en polarisation VV entre 2018 et 2020 sur des polygones de déforestation

La chute de signal s'explique par la sensibilité du rayonnement électromagnétique à l'eau et à l'humidité. En présence de végétation, la rétrodiffusion volumétrique est plus importante, particulièrement lorsque le couvert est dense. La contribution du sol est alors faible dans le signal de rétrodiffusion.

Lorsque la surface est déforestée, la sensibilité du signal dépend ainsi uniquement de la rétrodiffusion de surface. Un terrain plat, sans humidité, sans repousse et sans débris aura alors un signal très faible.

➤ Médianes

Le signal des médianes en polarisation VV et VH est très similaire à celui des moyennes (figures 27 et 28). Cela s'explique par la similarité statistique des deux mesures. Les métriques trimestrielles sont calculées avec 7 à 8 valeurs et les moyennes et les médianes sont semblables. Cela signifie que les métriques trimestrielles comprennent un nombre d'acquisitions potentiellement suffisant pour que l'échantillon soit relativement représentatif.

La médiane en polarisation VH présente donc un signal similaire à celui de la moyenne, affichant une chute brusque pour le 1^{er} échantillon, et des chutes plus douces pour les autres échantillons.

La médiane étant un indicateur de tendance centrale, cette statistique sera efficace pour représenter la déforestation et sera en effet considérée comme une métrique particulièrement significative dans la suite des analyses.




Figure 27 : Évolution du signal des médianes trimestrielles normalisées en polarisation VH entre 2018 et 2020 sur des polygones de déforestation




Figure 28 : Évolution du signal des médianes trimestrielles normalisées en polarisation VV entre 2018 et 2020 sur des polygones de déforestation

➤ Q10

Le quantile 10 est la statistique rassemblant les 10 % des valeurs les plus faibles de chaque pixel sur une période. Le quantile est ensuite calculé en moyennant ces valeurs sur le polygone. La chute de signal illustrant la déforestation est donc accentuée pour cette statistique. Le signal précédent la date de déforestation semble être moins bruité en polarisation VV (figure 30) tandis que le signal suivant la déforestation est plus stable en polarisation VH (figure 29). En effet, le signal en polarisation VV présente un pic à la suite de la déforestation de certains polygones, similaire aux métriques précédentes.

Les 2 polarisations apportent des informations distinctes et seront toutes deux significativement exploitées par la suite.




Figure 29 : Évolution du signal des quantiles 10 trimestriels normalisés en polarisation VH entre 2018 et 2020 sur des polygones de déforestation




Figure 30 : Évolution du signal des quantiles 10 trimestriels normalisés en polarisation VV entre 2018 et 2020 sur des polygones de déforestation

Le signal du quantile est affecté par les surfaces lisses. La présence de débris ou de rugosité affecte peu le signal, car seules les plus faibles valeurs du signal, c'est-à-dire celles d'une surface plane, seront sélectionnées par le quantile.

➤ Q90

Le quantile 90 représente, comme le quantile 10, les valeurs extrêmes d'un échantillon, c'est-à-dire les 10 % des valeurs les plus élevées situées dans chaque polygone. Le signal de cette métrique présente des chutes de signal dues à la déforestation, mais également des pics de changement de couvert autre que la déforestation. Le signal en polarisation VH illustre bien les périodes de déforestation par des chutes de signal marquées (figure 31) tandis que la polarisation VV illustre moins précisément les périodes de déforestation, mais présente certains changements de végétation (figure 32), comme

l'atteste le pic de signal au 3^e trimestre de 2018. Sur des images d'optique, la zone ne subit pas de déforestation. Cependant, la variation de signal peut être expliquée par la coupe d'arbres de la canopée supérieure, causant une diminution de rétrodiffusion adjacente à une augmentation, même si la canopée inférieure couvre encore toute la zone. Étant donné que les 2 polarisations des quantiles semblent fournir des informations distinctes, les 2 polarisations des quantiles seront exploitées dans les compositions colorées et dans les classifications afin d'exploiter leur potentiel.




Figure 31 : Évolution du signal des quantiles 90 trimestriels normalisés en polarisation VH entre 2018 et 2020 sur des polygones de déforestation




Figure 32 : Évolution du signal des quantiles 90 trimestriels normalisés en polarisation VV entre 2018 et 2020 sur des polygones de déforestation

À l'inverse du quantile 10, le quantile 90 sera impacté par les débris, les repousses et la rugosité des zones déforestées, car ce sont les éléments rétrodiffusant un signal plus élevé.

L'ensemble des métriques permet d'identifier 3 comportements du signal face à un évènement de déforestation :

- Le signal chute puis remonte brusquement. Cela correspond à une coupe brusque du couvert forestier suivie d'une repousse rapide d'un couvert herbacé (Échantillons 1, 2 et 3). Le pic de signal de plusieurs métriques en polarisation VV pourrait être dû à un retour rapide de la végétation donnant suite à une coupe rase, immédiatement suivie d'une seconde coupe.
- Le signal chute brusquement et remonte ensuite lentement, pour atteindre finalement une valeur plus élevée qu'au départ. Cette variation de signal correspond à une coupe brusque du couvert forestier suivie d'une repousse lente de la végétation (Échantillon 4).
- Le signal chute brusquement, mais cette variation de signal est inférieure à celle présentée par les autres échantillons. Ensuite, le signal reste à un niveau bas durant tout un trimestre avant de remonter à une valeur moins élevée que celle de départ. Le signal forme ainsi une cuvette et correspond à une coupe du couvert forestier dont la repousse se produit deux trimestres

plus tard, illustrant un sol nu pendant une longue période (Échantillons 5 et 6). Ces échantillons représentent l'aménagement de pistes d'exploitation. Ces séries temporelles illustrent particulièrement bien le comportement forestier lors de tels aménagements.

L'analyse des séries temporelles ci-dessus nous permet d'identifier les métriques dont les variations de signal représentent le mieux la déforestation. Les médianes en polarisation VH, les quantiles en polarisation VV et VH et les écarts-types en polarisation VV et VH seront donc des éléments importants dans les compositions colorées et les classifications qui vont suivre.

L'écart-type n'a pas été analysé dans les séries temporelles. Cependant, ayant été un facteur dans la normalisation et étant une métrique statistique illustrant des changements, cette métrique sera intégrée dans les compositions colorées et dans les classifications, ainsi que l'ensemble des métriques ayant présenté des informations concernant la période de déforestation.

Cohérence

Comme mentionné précédemment, la cohérence apporte des informations plus précises lorsqu'elle est analysée image par image. Les figures 33 et 34 présentent l'évolution du signal sur des polygones de déforestation. On peut ainsi observer que le signal de cohérence augmente après la date de changement de couvert, et non à la date exacte de déforestation. En effet, la cohérence mesure la différence de signal entre deux mesures. La cohérence est faible lorsqu'une surface est couverte de végétation, à cause du mouvement des feuilles et des branches. Elle reste également faible entre la date précédant la déforestation et la date de déforestation. C'est uniquement à partir de la seconde date de couvert déforesté que l'augmentation de cohérence se produit, la végétation étant absente lors des 2 dates et ne pouvant pas provoquer de perte de cohérence.

La cohérence est donc plus élevée lorsque la différence de signal entre deux mesures est importante, après la déforestation. On voit par exemple sur les figures 33 et 34 que l'échantillon 4 est déforesté à la date du 13/05/2019, son signal ayant augmenté brusquement à la date du 06/06/2019 sur la série temporelle des polygones de déforestation, tandis qu'il reste bas avant et après cet évènement.




Figure 33 : Évolution du signal de la cohérence normalisée en polarisation VV sur l'année 2019, sur des polygones de déforestation




Figure 34 : Évolution du signal de la cohérence normalisée en polarisation VH sur l'année 2019, sur des polygones de déforestation

La comparaison des figures 33 et 34 permet d'identifier les différences de signal entre les polarisations VV et VH. On constate ainsi que la polarisation VV accentue plus la déforestation étant donné que le signal est plus fort. De plus, les dates auxquels le signal augmente en polarisation VH ne correspondent pas précisément aux dates de déforestation, contrairement au signal en polarisation VV. Pour la suite de l'analyse de la cohérence, nous allons donc analyser le signal de la polarisation VV.

L'hypothèse émise dans la méthodologie, selon laquelle les mesures annuelles, semestrielles et trimestrielles sont moins précises que les mesures par dates, est vérifiée pour les mesures annuelles et semestrielles (figures 35 et 36), mais on constate tout de même que les mesures trimestrielles portent de l'information, dans la figure 37. On constate par exemple que l'échantillon 1 est déforesté au second trimestre de 2019.




Figure 35 : Évolution du signal des moyennes annuelles normalisées en polarisation VV entre 2018 et 2020 sur des polygones de déforestation




Figure 36 : Évolution du signal des moyennes semestrielles normalisées en polarisation VV entre 2018 et 2020 sur des polygones de déforestation




Figure 37 : Évolution du signal des moyennes trimestrielles normalisées en polarisation VV entre 2018 et 2020 sur des polygones de déforestation

Les moyennes annuelles et semestrielles lissent donc trop l'information pour qu'elles puissent être exploitées. Cependant, les mesures trimestrielles de cohérences portent de l'information et pourront donc être exploitées dans les analyses suivantes

f) Sélection des variables les plus informatives

Dans cette partie des résultats, les métriques significatives identifiées au point précédent sont combinées afin de mettre en évidence les zones dont le couvert forestier change au cours d'une période définie.

Le but de ces compositions colorées est d'apprécier visuellement les changements forestiers avant d'en faire la classification sur base quantitative.

L'ensemble des métriques en polarisation VV, VH ainsi que le ratio constitueront le jeu de données entraînant la classification par pixel. Aucune métrique n'est écartée de cette classification.

La classification par objet nécessitant une étape de délimitation et de caractérisation de chaque objet, une sélection des métriques doit donc être effectuée, en fonction des observations effectuées précédemment.

Les compositions colorées construites à l'aide de métriques de cohérence sont plus bruitées que celles d'amplitude. Cela est dû à l'observation faite au point b), qui indiquait que la cohérence était visuellement bruitée et qu'une représentation de cette mesure n'était pas efficace étant donné que les informations intrinsèques ne se lisaient pas visuellement.

Étant donné que la polarisation VH traduit les effets de dépolarisation croissante liée à la rétrodiffusion volumétrique, tandis que la polarisation VV transmet et reçoit verticalement et directement son signal, on peut s'attendre à ce que la polarisation VV soit moins bruitée que la polarisation VH, mais également moins sensible au couvert végétal. Cette hypothèse est confirmée pour certaines métriques dans les compositions colorées. Les quantiles et la médiane sont moins bruités en polarisation VV. L'écart-type est plus précis dans la polarisation VH.

Enfin, le ratio est exclu des compositions colorées, car son effet poivre et sel tache le résultat final.

La figure 38 présente une composition colorée représentant le changement forestier sur 3 ans (entre 2018 et 2020) à l'aide de la métrique du quantile 10. On constate que cette métrique met en évidence le changement forestier. La couronne agricole présente autour de Pokola est donc colorée en fonction du changement de couvert subi ainsi qu'en fonction de la période durant laquelle le changement s'est produit.




Figure 38 : Composition colorée représentant le changement du couvert forestier sur 3 ans à l'aide des quantiles 10(B1 : VV 2018, B2 : VV 2019, B3 : VV 2020)




Figure 39 : Composition colorée représentant le changement du couvert forestier en 2019 (B1 : médiane VV, B2 : médiane VH, B3 : écart-type VH)

La combinaison des médianes dans chaque polarisation et de l'écart-type dans la polarisation VH accentue le changement de texture en particulier. La figure 39 présente des changements de couleurs dans des zones possédant un couvert forestier dense, mais dont les essences diffèrent des autres zones alentour et dont la texture est donc différente. Cette composition colorée permet également de mettre en évidence les changements de couvert dans l'auréole agricole autour de Pokola et de Mboko ainsi que les zones urbaines, qui sont représentées en rouge et noir.

La combinaison des écarts-types dans les deux polarisations et de la médiane dans la polarisation VH fournit un résultat similaire à la figure précédente. Cependant, le résultat est plus facilement interprétable, car les couleurs issues de cette composition colorée augmentent les contrastes entre les zones déforestées et les autres occupations du sol des alentours de Pokola et de Mboko (figure 40).




Figure 40 : Composition colorée représentant le changement du couvert forestier en 2019 (B1 : écart-type VV, B2 : écart-type VH, B3 : médiane VH)




Figure 41 : Composition colorée représentant le changement du couvert forestier en 2019 (B1 : moyenne VH, B2 : q90 VH, B3 : écart-type VH)

La figure 41 apporte des informations sur la déforestation exclusivement. Ainsi, ces compositions colorées sont plus épurées et permettent donc de se concentrer sur l'information voulue, c'est-à-dire identifier les zones de déforestation. En zoomant sur les alentours de Pokola, on visualise plus facilement les changements de couvert qui s'y produisent. Les tâches turquoise représentent les zones déforestées au cours de l'année 2019. La combinaison des moyennes, q90 et écarts-types en polarisation VH (figure 41) est donc une combinaison appropriée à l'objectif poursuivi dans ce mémoire. Les métriques ayant produit ces compositions colorées sont donc des métriques à exploiter dans le suivi de la déforestation.

La combinaison des écarts-types, des médianes et des quantiles 90 fournit également des informations importantes. En effet, les figures 42 et 43 mettent en évidence les zones de déforestation ainsi que les zones subissant un changement de couvert menant à un changement de texture.

On constate également que les bandes dans lesquelles les métriques sont placées ainsi que les polarisations utilisées ont leur importance. L'écart-type en polarisation VH et la médiane en polarisation VH, suivie pour la troisième bande du quantile 90 dans la polarisation VV (figure 42) présentent ainsi un meilleur contraste et plus de nuances de couleur qu'un autre ordre de combinaison de ces mêmes métriques.




Figure 42 : Composition colorée représentant le changement du couvert forestier en 2019 (B1 : écart-type VH, B2 : médiane VH, B3 : q90 VV)




Figure 43 : Composition colorée représentant le changement du couvert forestier en 2019 (B1 : écart-type VH, B2 : q90 VH, B3 : médiane VH)

Ainsi, l'écart-type en bande 1, le quantile 90 en bande 2 et la médiane en bande 3, tous les 3 en polarisation VH fournissent également des informations sur la situation des zones de déforestation, mais de façon moins nuancée et moins contrastée.

L'analyse des différentes compositions colorées produites fournit donc des informations variables en fonction des métriques, des polarisations et des combinaisons de ces métriques aux couleurs primaires. En fonction de la combinaison, on aura donc des informations sur la localisation des zones déforestation, sur le type de forêts présentes ainsi que sur d'autres phénomènes causant des changements de texture.

L'analyse de ces différentes compositions indique également que les quantiles 10 et 90 sont les métriques apportant les informations les plus contrastées. En effet, la figure 38 présente des variations de couleurs plus importantes que les autres compositions colorées, et apporte donc plus d'informations sur la période et la durée de la déforestation. Les figures 41, 42 et 43 présentent également beaucoup de contraste de couleurs au niveau des zones déforestées. L'hypothèse émise pour expliquer la différence d'impact entre les quantiles et les autres métriques est que la déforestation représente une surface marginale. En effet, elle est comprise dans les 10 % des valeurs extrêmes et donc dans les quantiles. Les surfaces déforestées produisent donc un signal extrême dont les valeurs sont reprises dans les quantiles.

On constate également, lors de l'analyse de ces compositions colorées, que des zones de forêt sont parfois colorées de la même couleur que des zones déforestées. Cela est dû au fait que les caractéristiques de ces zones perçues par le satellite sont similaires aux caractéristiques des zones déforestées. Ces zones présentant probablement une variabilité, un taux d'humidité ou une rugosité similaire aux zones déforestées, il faut envisager des traitements de données permettant de différencier efficacement ces couverts.

Les moyennes normalisées et filtrées peuvent également être superposées de façon à obtenir une vision d'ensemble du changement forestier qui s'est produit sur la zone d'étude entre 2017 et 2019 (figure 44).




Figure 44 : Déforestation annuelle entre 2017 et 2020, mesurée à l'aide des moyennes annuelles en polarisation VV

Pour représenter les zones de déforestation, on sélectionne un seuil arbitraire au-delà duquel on considère les valeurs comme étant suffisamment élevées pour être considérée comme représentative de la déforestation. Ainsi, les valeurs situées entre -25 et 25dB sont considérées comme stables, et au-delà ou en deçà de cet intervalle, on considère qu'il y a du changement.

Le seuil a été déterminé par essais-erreur, afin de réduire au maximum le bruit, mais sans perdre de l'information. Un compromis doit donc être trouvé entre bruit et information.

La méthode étant arbitraire, une autre méthode doit être développée pour s'affranchir de l'étape de seuillage arbitraire et pour développer une validation plus efficace. Le point suivant va donc présenter les résultats des classifications résolvant les écueils de la méthode précédente. La classification permet également de prendre en compte l'ensemble des métriques et pas seulement les moyennes, ce qui renforce son effectivité, comparée à la méthode précédente.

g) Classification

Classification par pixel

Les classifications par pixel réalisées à l'aide de l'ensemble des métriques normalisées et filtrées, de cohérence et de rétrodiffusion, dans toutes les polarisations, sont produites et représentées ci-dessous. L'algorithme détermine lui-même l'importance de chaque métrique dans la classification.

Afin de faciliter la visualisation, les résultats seront présentés d'abord sur une zone restreinte, avant de présenter le résultat final sur la zone d'étude entière.




Figure 45 : Déforestation annuelle de 2019 issue d'une classification par pixel




Figure 46 : Déforestation trimestrielle de 2019 issue d'une classification par pixel

La figure 45 présente la classification déforestation/forêt stable issue de la méthodologie basée sur le RF présentée précédemment pour l'année 2019. Chaque pixel de la zone d'étude se voit ainsi attribuer une valeur de déforestation ou de non-déforestation. Les classifications annuelles réalisées pour les années 2017, 2018 et 2020 peuvent être consultées en annexe 2.

On constate que les zones de déforestation sont situées principalement dans l'auréole agricole de Pokola, ainsi que le long de nouvelles pistes d'exploitation. Il semble qu'une partie de l'information est perdue, car les chemins d'exploitations identifiés comme des zones de déforestation sur la carte de Vancutsem *et al.* (2021) ne sont que partiellement identifiés comme des zones de déforestation dans les résultats de la classification par pixel.

Cette limite peut s'expliquer par une calibration trop précise, axée sur les zones de déforestation périurbaines, ou par une utilisation non optimale de l'algorithme RF. Ce dernier détermine l'importance de chaque métrique dans le processus de décision, et le nombre important de métriques peut diluer l'information.

On constate également que la classification est peu bruitée, ce qui indique que la normalisation et le filtrage présentés en début de travail sont efficaces. Bien que la classification soit efficace, l'échantillonnage effectué à l'année présente certains défauts. En effet, certaines zones sont identifiées comme des zones de déforestation, mais sont reboisées avant la fin de l'année. Ces zones présentent donc des caractéristiques variables au cours de l'année. De plus, cette méthode permet d'identifier uniquement l'année de déforestation, sans précision sur la période de l'année à laquelle la déforestation se produit. Il est donc intéressant de réduire le pas de temps de la méthode.

La figure 46 présente le résultat de la classification par pixel pour chaque trimestre de l'année 2019. Celle-ci permet d'identifier le trimestre durant lequel chaque événement de déforestation a lieu. On constate une perte d'information par rapport à la classification de déforestation annuelle. Cependant, l'information perdue pourrait être du bruit, et la classification trimestrielle permettrait ainsi de s'affranchir du bruit, potentiellement causé par l'échantillonnage annuel qui n'est pas suffisamment précis. Les classifications trimestrielles, calibrées et appliquées individuellement pour les années 2017, 2018 et 2020, peuvent être consultées en annexe 2.

La superposition des classifications annuelles (figure 47) et trimestrielles (figure 48) de 2017 à 2020 permet d'obtenir une vue d'ensemble des événements de déforestation durant ces 4 années




Figure 47 : Déforestation autour de Pokola sur base annuelle entre 2017 et 2020 issue d'une classification par pixel

Les classifications annuelles permettent de distinguer les années durant lesquels chaque surface représentée sur la figure 47 est déforestée. En occultant l'occupation du sol qui n'est pas pertinente, c'est-à-dire l'occupation urbaine, agricole et l'afforestation, les zones de déforestation identifiées à l'aide des classifications par pixel sont mises en évidence. Le front de déforestation semble en effet reculer, puisque les zones déforestées en 2017 sont les plus proches du centre urbain. Ensuite, les zones de déforestation s'éloignent du centre lorsque l'évènement de déforestation se déroule dans les années qui suivent. Les zones de déforestation de 2020 sont ainsi les plus éloignées du centre urbain.




Figure 48 : Déforestation autour de Pokola sur base trimestrielle entre 2017 et 2020 issue d'une classification par pixel

Les mêmes observations peuvent être effectuées pour les classifications par trimestre. On peut attribuer à chaque zone de déforestation le trimestre durant lequel la déforestation s'est produite. Les zones de déforestation datant de 2017 sont les plus proches du centre urbain, et les zones de déforestation les plus récentes sont les plus éloignées du centre urbain.

La carte de Vantcutsem *et al.* est ici utilisée comme Forest mask. En occultant la dégradation de la forêt ainsi que la déforestation antérieure à 2017 (figure 49), il est aisé de repérer le retrait du front forestier autour de Pokola. On voit ainsi sur 4 ans, entre 2017 et 2020, une diminution graduelle de la surface forestière entourant Pokola. Les déforestations les plus proches du centre urbain sont en teintes claires et correspondent aux déforestations datant de 2017. Les teintes plus sombres représentées sur la carte correspondent aux déforestations se produisant plus récemment, et se situent à proximité de la forêt.




Figure 49 : Déforestation autour de Pokola sur base trimestrielle entre 2017 et 2020 issue d'une classification par pixel occultant la déforestation antérieure à 2017

Classification par objet

Le processus de caractérisation de chaque segment par l'ensemble des métriques étant particulièrement long, il est intéressant d'étudier l'importance des différentes métriques et des différentes polarisations dans l'identification des zones de déforestation. On exclut donc d'abord les métriques de cohérence et de ratio, celles-ci ayant été précédemment considérées comme moins significatives que les métriques de rétrodiffusion dans le suivi de la déforestation.

Ainsi, les figures 50, 51 et 52 présentent les classifications de chaque segment en zone de déforestation ou non sur l'année 2019, successivement entraînées et classifiées sur base des polarisations VV, la polarisation VH et les 2 polarisations. On constate que la polarisation VV (figure 49) est plus précise dans l'identification des zones de déforestation que la polarisation VH (figure 50), les zones de déforestations identifiées correspondant au mieux aux zones identifiées comme étant des zones déforestées sur la carte de Vantcutsem *et al.* (2021).




Figure 50 : Déforestation annuelle de 2019 issue d'une classification par objet entraînée par des métriques en polarisation VV




Figure 51 : Déforestation annuelle de 2019 issue d'une classification par objet entraînée par des métriques en polarisation VH





Figure 52 : Déforestation annuelle de 2019 issue d'une classification par objet entraînée par des métriques en polarisation VV et VH

La combinaison des 2 polarisations semble, quant à elle, bruyant le résultat final et ne semble pas fournir en contrepartie plus d'informations concernant les zones de déforestation (figure 52). Le choix des données d'entraînement pour la classification par objet se porte donc sur l'ensemble des métriques significatives en polarisation VV. Le seuil a été déterminé par essais-erreur, afin de réduire au maximum le bruit, mais sans perdre de l'information. Un compromis doit donc être trouvé entre bruit et information.

La figure 53 présente l'identification des zones de déforestation trimestrielle de 2019 issue de la classification par objet. En occultant l'occupation du sol qui n'est pas pertinente, c'est-à-dire l'occupation urbaine, agricole, la déforestation antérieure à la période d'étude ainsi que la repousse forestière, les zones de déforestation identifiées sont mises en évidence. On constate, comme pour la classification par pixel, qu'une partie de l'information est perdue lorsque le pas de temps de la classification diminue. Cependant, on émet la même hypothèse que précédemment, c'est-à-dire que les informations perdues correspondent en réalité à du bruit. En effet, certaines zones identifiées comme des zones déforestées en 2019 sont en réalité des zones déforestées durant des années antérieures, et ne correspondent donc pas à des zones déforestées durant l'année 2019. Les mêmes constatations peuvent être effectuées pour les classifications des années 2017, 2018 et 2020. Les classifications annuelles et trimestrielles réalisées pour les années 2017, 2018 et 2020 peuvent être consultées en annexe 2.



La superposition des classifications annuelles (figure 54) et trimestrielles (figure 55) de 2017 à 2020 permet de repérer le retrait du front forestier, notamment autour de Pokola.

Les classifications annuelles permettent de distinguer aisément l'avancement des terres agricoles, faisant reculer le front forestier année après année.

Figure 53 : Déforestation trimestrielle de 2019 issue d'une classification par objet




Figure 54 : Déforestation autour de Pokola sur base annuelle entre 2017 et 2020 issue d'une classification par objet

Les classifications trimestrielles permettent également de distinguer le défrichement des terres agricoles, trimestre par trimestre. Le résultat est plus précis et moins bruité que celui de la classification par pixel.




Figure 55 : Déforestation autour de Pokola sur base trimestrielle entre 2017 et 2020 issue d'une classification par objet

La méthode permet donc de distinguer les années de déforestation, mais également les trimestres durant lesquels ces zones sont déforestées. Les 2 types de classifications semblent produire des résultats correspondant à la réalité. Visuellement, la classification par objet semble être la plus efficace, car les zones de déforestation sont plus distinctes en fonction de la période de déforestation et le résultat semble moins bruité. Cependant, une validation est nécessaire afin d'examiner les performances des 2 types de classifications.

h) Validation

Les résultats obtenus par classification sont ensuite validés à l'aide des polygones de validation définis précédemment. Afin d'obtenir une représentativité optimale, le nombre de pixels est identique dans chaque classe à valider.

Validation des classifications à l'aide de l'exactitude générale

Les classifications à l'échelle annuelle produisent des performances légèrement supérieures pour les classifications par objet (tableau 3), excepté pour l'année 2018 qui semble avoir été mal calibrée. La classification par pixel présente un niveau moyen de performance plus stable, aucune année n'ayant été mal calibrée et la différence entre la performance de 2019 et celles des autres années étant plus faible que dans la classification par objet. Ces performances sont évaluées en fonction du nombre de pixels ayant été identifiés correctement.

/	Exactitude générale des classifications par pixel	Exactitude générale des classifications par objet	Classification par pixel				Classification par objet			
			N polygones		N pixels		N polygones		N pixels	
			cal	val	cal	val	cal	val	cal	val
2017	74,9%	86,3%	166	69	18840	2104	516	92	41552	6563
2018	82,8%	69,4%	41	99	14393	2854	271	45	21037	3201
2019	95,1%	96,4%	74	134	5602	1679	268	118	21549	8956
2020	77,4%	89,3%	52	93	12324	542	258	50	20309	3614

Tableau 3 : Performance des classifications annuelles par pixel et par objet

L'année performant le mieux dans les 2 types de classification est 2019. C'est également l'année ayant été la plus étudiée du point de vue visuel, ce qui explique probablement cette bonne performance. L'analyse complète des autres années permettrait donc potentiellement de fournir les mêmes performances que pour l'année 2019. En rapportant les exactitudes obtenues aux nombres de polygones et de pixels utilisés pour la calibration et la validation, on peut s'affranchir du biais.




Figure 56 : Performances des classifications par pixel rapportées aux nombres de pixels de calibration et de validation




Figure 57 : Performances des classifications par pixel rapportées aux nombres de polygones de calibration et de validation




Figure 58 : Performances des classifications par objet rapportées aux nombres de pixels de calibration et de validation




Figure 59 : Performance des classifications par objet rapportées aux nombres de polygones de calibration et de validation

L'analyse des figures 57 et 59 permet d'identifier l'impact du nombre de polygones de calibration et de validation sur la performance des classifications. On constate que le nombre de polygones de calibration et de validation impacte les classifications, étant donné que les classifications sont au même niveau de performance lorsqu'on les rapporte au nombre de polygones. Les polygones pouvant avoir des surfaces très variables, leur valeur est moins significative que celle du nombre de pixels.

Les figures 56 et 58 illustrent que, même en s'affranchissant du nombre de pixel, les performances de l'année 2019 restent supérieures. En effet, le nombre de pixels de calibration des classifications par objet est très proche pour 2018, 2019 et 2020 (en rouge dans le tableau 3). L'affranchissement de cette variable ne modifie donc pas beaucoup les exactitudes. Le nombre de pixels des classifications par pixel ne sont pas les mêmes, cependant la classification de 2019 n'en est que meilleure. On constate également que les polygones de validation pour l'année 2020 étaient peu nombreux et que cela a peut-être mené à une sous-estimation de la performance réelle de la classification de 2020.

Avec des moyennes d'exactitude générale respectivement de 82,6 % et de 85,4 % les classifications par pixel et par objet annuelles sont efficaces. Néanmoins, les polygones de validation sont localisés et tracés arbitrairement pour la classification par pixel. Les résultats efficaces sont donc potentiellement limités aux zones dans lesquelles les polygones de validation sont situés. Mais le pourcentage élevé d'exactitude générale permet tout de même d'accorder une confiance élevée aux résultats obtenus.

Les polygones de validation de la classification par objet sont plus objectifs, car ils sont issus de la segmentation et non tracés à la main. Cependant, les polygones de validation ne couvrent pas l'entièreté de la zone d'étude. Certaines erreurs ont donc pu être omises. De plus, leur composition pouvant parfois contenir différents types de pixels, les polygones de calibration et de validation ont été considérés comme déforestés lorsque 75 % des pixels ou plus étaient déforestés. Certains polygones ne sont donc pas totalement déforestés et peuvent créer un biais dans le modèle. Mais, comme pour la classification par pixel, les pourcentages d'exactitude sont encourageants.

/	Exactitude générale des classifications par pixel	Exactitude générale des classifications par objet
1 ^{er} trimestre de 2019	81 %	87,2 %
2 ^e trimestre de 2019	96,2 %	96,5 %
3 ^e trimestre de 2019	97,2 %	97,5 %
4 ^e trimestre de 2019	92,6 %	75,7 %

Tableau 4 : Performance des classifications trimestrielles de l'année 2019, par pixel et par objet

Les classifications à l'échelle trimestrielle produisent, à l'inverse des classifications annuelles des meilleures performances pour les classifications par pixel, bien que la différence ne soit pas marquée. Les classifications de l'année 2019 sont celles produisant les exactitudes les plus élevées, pour les mêmes raisons qu'énoncées précédemment (tableau 4). L'absence d'écart majeur entre les exactitudes générales des 2 classifications limite la comparaison entre ces dernières.

La figure 60 représente les pourcentages d'exactitude pour chaque trimestre, et la figure 61 représente ces mêmes pourcentages rapportés au nombre de pixels de calibration et de validation, le nombre de polygones influençant moins le résultat comme vu ci-dessus.




Figure 60 : Performances des classifications trimestrielles par pixel et par objet




Figure 61 : Performances des classifications trimestrielles par pixel et par objet, rapportées au nombre de pixels de calibration et de validation

Le tableau présentant les exactitudes générales et le nombre de pixels des polygones de calibration et de validation pour chaque trimestre peut être consulté en annexe 3.

Les classifications des trimestres de l'année 2019 restent celles ayant la performance la plus élevée, même en étant affranchie du nombre de pixel de calibration et d'entraînement. Cependant, l'écart de performance entre les trimestres est réduit, particulièrement pour la classification par objet affranchie du nombre de pixels de calibration.

Avec des moyennes d'exactitude générale respectivement de 75,9 % et de 71,6 %, les classifications par pixel et par objet trimestrielles ont tendance à être moins efficaces que les classifications annuelles. Au sein des classifications trimestrielles, les résultats sont meilleurs pour les classifications trimestrielles de l'année 2019 que pour les autres, l'année 2019 étant la plus étudiée.

Ces tendances confirment l'hypothèse émise plus haut, selon laquelle plus les zones de déforestations sont nombreuses, mieux le modèle peut être calibré, meilleurs seront les résultats. Une année comportant évidemment plus de zones de déforestation qu'un trimestre, les classifications annuelles

sont donc mieux calibrées que les classifications trimestrielles. Cela s'explique également par la différence de données en input. En effet, une moyenne annuelle sera plus robuste qu'une moyenne trimestrielle puisqu'elle comporte un plus grand nombre de mesures.

Afin d'approfondir l'analyse des performances des classifications, d'autres métriques d'exactitude peuvent être calculées.

Validation des classifications à l'aide de l'exactitude de l'utilisateur et du producteur

L'exactitude de l'utilisateur représente le pourcentage de pixels identifiés comme de la déforestation qui correspond réellement à la déforestation.

L'exactitude du producteur représente, quant à elle, le pourcentage de déforestation réelle identifiée correctement comme de la déforestation dans la classification.

	Classification par pixel		Classification par objet	
	Exactitude de l'utilisateur	Exactitude du producteur	Exactitude de l'utilisateur	Exactitude du producteur
2017	99,8 %	53,8 %	100 %	73,2 %
2018	97,9 %	63,6 %	100 %	30,4 %
2019	100 %	89,6 %	97,1 %	93,9 %
2020	85,3 %	46 %	87,4 %	90,3 %

Tableau 5 : Exactitude de l'utilisateur et du producteur des classifications annuelles pour la déforestation

L'analyse des résultats du tableau 5 confirme l'observation émise ci-dessus, selon laquelle les classifications annuelles par objet performant mieux que les classifications annuelles par pixel, bien que l'écart ne soit pas prononcé. En effet, les exactitudes de l'utilisateur des classifications par objet et par pixel valent respectivement 96,12 % et 95,76 %, tandis que les exactitudes du producteur valent 71,93 % et 63,26 %. Cette tendance est à confirmer dans un test statistique.

	Classification par pixel		Classification par objet	
	Exactitude de l'utilisateur	Exactitude du producteur	Exactitude de l'utilisateur	Exactitude du producteur
1 ^{er} trimestre de 2017	89,4 %	50,1 %	100 %	14,9 %
2 ^e trimestre de 2017	100 %	82 %	100 %	34,1 %
3 ^e trimestre de 2017	100 %	70,7 %	100 %	21 %
4 ^e trimestre de 2017	100 %	68,8 %	100 %	6,6 %
1 ^{er} trimestre de 2018	88,9 %	3,5 %	100 %	9 %
2 ^e trimestre de 2018	77 %	44,8 %	100 %	5,3 %
3 ^e trimestre de 2018	83,8 %	92,6 %	0 %	0 %
4 ^e trimestre de 2018	100 %	44,4 %	100 %	21,5 %
1 ^{er} trimestre de 2019	100 %	56,7 %	100 %	67,5 %
2 ^e trimestre de 2019	100 %	94 %	100 %	94,5 %
3 ^e trimestre de 2019	100 %	90,8 %	100 %	93,4 %
4 ^e trimestre de 2019	100 %	87 %	89,7 %	48 %
1 ^{er} trimestre de 2020	100 %	34 %	100 %	17,1 %
2 ^e trimestre de 2020	97,3 %	20,9 %	100 %	78,1 %
3 ^e trimestre de 2020	0 %	0 %	100 %	42,4 %
4 ^e trimestre de 2020	100 %	89,3 %	100 %	28,2 %

Tableau 6 : Exactitude de l'utilisateur et du producteur des classifications trimestrielles pour la déforestation

En analysant le tableau 6, on constate que la classification par pixel performe mieux que la classification par objet, excepté pour l'année 2020. En effet, les exactitudes de l'utilisateur des classifications par objet et par pixel valent respectivement 93,1 % et 89,8 %, tandis que les exactitudes

du producteur valent 36,3 % et 53,8 %. En combinant ces pourcentages aux moyennes d'exactitudes générales calculées ci-dessus (76 % pour la classification par pixel et 71,6 % pour la classification par objet), on peut donc estimer que la classification par pixel, bien qu'elle semble plus bruitée que la classification par objet, est plus performante pour les classifications trimestrielles. Cependant, les classifications trimestrielles sont en général moins performantes que les classifications annuelles, comme cela a été établi ci-dessus.

On peut calculer également l'erreur d'omission et l'erreur de contamination à l'aide de ces valeurs, puisque l'erreur d'omissions vaut le complémentaire de l'exactitude du producteur (1-exactitude du producteur), et que l'erreur de contamination vaut le complémentaire de l'exactitude de l'utilisateur (1-exactitude de l'utilisateur).

Les classifications par objet présentent donc des erreurs d'omissions élevées, l'exactitude du producteur étant pour la majorité des trimestres inférieure à 50 % dans la classification par objet.

Les exactitudes de l'utilisateur sont, quant à elle, particulièrement élevées. L'erreur de contamination étant donc basse, les zones identifiées comme étant déforestées l'étaient presque systématiquement.

Il n'y a donc presque pas d'erreur de contamination, excepté certains trimestres présentant une exactitude de l'utilisateur de 0, due à une absence de pixels identifiés comme étant déforestés.

L'analyse des exactitudes liées à la forêt, et non à la déforestation (tableau 7), permet d'établir que les classifications par pixel et par objet sont spécifiques, la spécificité étant évaluée par rapport à la capacité à identifier les pixels de forêt correctement, et donc identifier l'absence de déforestation, qui définit la spécificité. Avoir une exactitude du producteur pour la forêt élevée permet donc d'évaluer la spécificité comme étant élevée.

/	Exactitude du producteur des classifications par pixel	Exactitude du producteur des classifications par objet
1 ^{er} trimestre de 2017	100 %	100 %
2 ^e trimestre de 2017	100 %	100 %
3 ^e trimestre de 2017	100 %	100 %
4 ^e trimestre de 2017	100 %	100 %
1 ^{er} trimestre de 2018	99,5 %	100 %
2 ^e trimestre de 2018	88,2 %	100 %
3 ^e trimestre de 2018	76,1 %	100 %
4 ^e trimestre de 2018	100 %	100 %
1 ^{er} trimestre de 2019	100 %	100 %
2 ^e trimestre de 2019	100 %	100 %
3 ^e trimestre de 2019	100 %	100 %
4 ^e trimestre de 2019	100 %	96 %
1 ^{er} trimestre de 2020	100 %	100 %
2 ^e trimestre de 2020	100 %	100 %
3 ^e trimestre de 2020	100 %	100 %
4 ^e trimestre de 2020	100 %	100 %

Tableau 7 : Exactitude du producteur des classifications trimestrielles par objet et par pixel pour la forêt stable

Il est important de noter que les zones de forêt stable sont plus grandes, et comportent donc plus de pixels que les zones de déforestation. Étant donné que nous avons sélectionné un nombre de pixels égal de forêt et de déforestation pour la validation, le nombre de polygones de déforestation nécessaire pour égaliser le nombre de pixels des grandes zones de forêt est plus élevé.

Chapitre 5 : Discussion

Dans ce chapitre final, deux aspects importants vont être abordés. Dans un premier temps, les résultats et les interprétations présentés au chapitre précédent vont être discutés afin d'évaluer les forces et les faiblesses de la méthode. Dans un second temps, un processus d'extraction du bruit va être présenté, ainsi qu'une confrontation des résultats avec la littérature scientifique. Le produit final de la méthodologie sera également présenté.

1) Comparaison des performances des 2 types de classification

L'analyse des performances des 2 types de classification effectuées ci-dessus présente des résultats ambigus. En effet, on remarque que les classifications annuelles par objet sur les 4 années étudiées sont en moyenne plus performantes que les classifications par pixel. À l'inverse, les classifications trimestrielles par pixel de ces 4 années sont plus performantes en moyenne que les classifications par objet.

Les classifications annuelles sont systématiquement plus efficaces que les classifications trimestrielles. Cela s'explique par la robustesse des moyennes ayant entraîné les classifications. En effet, les métriques ayant entraîné les classifications annuelles sont calculées sur une trentaine d'images tandis que les métriques trimestrielles sont moyennées sur 7 à 8 images.

La méthode générale la plus efficace est donc la classification par objet, qui est plus adaptée à une classification entraînée par des métriques de rétrodiffusion en polarisation VV moyennées par objet sur de nombreuses données, ainsi qu'ayant subi un traitement par filtre spatial.

Cependant, dans l'optique d'un suivi de la déforestation à haute résolution temporelle, les classifications trimestrielles par pixel sont plébiscitées, afin de réduire le pas de temps de la détection à 90 jours.

En comparant les classifications trimestrielles par objet et par pixel (figure 62), les résultats diffèrent sur plusieurs points. La déforestation identifiée ne se voit pas attribuer la même date de début de déforestation par les 2 méthodes. Les classifications par pixel identifient en général la déforestation plus tôt que les classifications par objet. Cela peut être dû à une surestimation de la déforestation dans la classification par pixel ou à une sous-estimation dans la classification par objet, causée par le lissage spatial lié à l'objet. Les résultats de la validation effectuée au point précédent indiquent que les erreurs d'omission sont plus fréquentes que les erreurs de contamination, la 2^e option semble donc la plus probable, c'est-à-dire que la classification par objet aurait omis de la déforestation et l'aurait détectée plus tard qu'elle ne l'était réellement.




Figure 62 : Comparaison des performances de la classification trimestrielle déforestation/non-déforestation par objet et par pixel ; (A) Classification par objet, (B) Classification par pixel.

Les superpositions de couches permettant d'identifier uniquement le début de la déforestation, les classifications par pixel semblent attribuer à une majorité de surfaces une date de déforestation appartenant aux trimestres de 2017. La fin de la période de déforestation peut être observée en annexe 2, dans laquelle les déforestations trimestrielles individuelles sont présentées. La repousse forestière peut donc y être observée.

Par ailleurs, les classifications par pixels sont plus bruitées que les classifications par objet. Cela est dû à la nature des types de classifications. Un pixel isolé identifié comme de la déforestation est plus susceptible de créer du bruit qu'un segment.

Le bruit de la classification par pixel provient d'un manque de données d'entraînement, les polygones de calibration et de validation étant moins abondants que ceux ayant entraîné la classification par objet. En effet, les polygones tracés à la main sont plus longs à effectuer qu'une sélection de polygones dans la segmentation. Le bruit provient également d'un facteur d'erreur humaine pouvant mener à une contamination, lors du traçage des polygones à la main. Malgré l'application d'un tampon de 10m sur chaque polygone, des erreurs restent envisageables. Un autre facteur d'erreur humaine est l'interprétation erronée du type de couvert des polygones. Enfin, le bruit provient également d'occupations du sol dont la signature spectrale est similaire à celle des surfaces déforestées et qui sont donc identifiées de façon erronée comme étant de la déforestation.

Le bruit issu des classifications par objet peut également provenir d'une erreur de signature spectrale. Une autre source de bruit, spécifique à la classification par objet, provient de la segmentation. En effet, bien que la segmentation à 10m permette en général de séparer les segments contenant de la forêt de ceux contenant des surfaces déforestées, certains segments se trouvent malgré cela de part et d'autre de la forêt et de la déforestation. Le signal de ces segments est alors bruité par ces segments

mixtes. Ces segments créent donc non seulement du bruit, mais également des erreurs de classifications.

Les erreurs d'omission sont causées par les mêmes sources que celles causant le bruit. Afin d'augmenter les pourcentages d'exactitude obtenus lors de la validation, celle-ci devrait être effectuée non seulement avec le même nombre de pixels, comme cela a été réalisé dans cette méthodologie, mais également avec le même nombre de polygones. En effet, comme cela a été mentionné dans les résultats, le nombre de polygones de validation de la forêt stable est moindre que celui de la déforestation. Égaliser le nombre de polygones permettrait d'obtenir de meilleurs résultats de validation.

2) Extraction du bruit

Les tâches de déforestation isolées dans les classifications étant identifiées comme du bruit et non comme de la déforestation, un traitement supplémentaire des résultats est nécessaire afin de les améliorer.




Figure 63 : Effet du filtrage sur la classification par pixel ; (A) Classification par pixel non filtrée, (B) Classification par pixel filtrée.

Le filtre utilisé est un filtre modifiant la valeur de chaque pixel par rapport à ses voisins à l'aide d'une fenêtre de 9 pixels. Ainsi, les pixels isolés se voient attribuer la valeur médiane de leur entourage et sont éliminés.

Le filtrage des classifications par pixel est particulièrement efficace (figure 63). L'effet poivre et sel provenant de la méthode est réduit par le filtre, et la déforestation réelle est mise en évidence.




Figure 64 : Effet du filtrage sur la classification par objet ; (A) Classification par objet non filtrée, (B) Classification par objet filtrée.

Le filtrage des classifications par objet est également efficace (figure 64). L'effet poivre et sel étant moins important que celui issu de la classification par pixel, l'impact du filtre est moins important. Les pixels effacés par ce filtre sont donc des pixels de bordures et des pixels appartenant à des segments de très petite taille.

Avec une exactitude générale de 75,9 %, les classifications trimestrielles par pixel voient leur précision moyenne baisser de 1,3 % par rapport aux résultats avant le filtrage. L'exactitude des classifications par objet baisse, quant à elle, de 2,2 % pour atteindre une exactitude générale de 69,4 %. L'impact négatif du filtre sur les résultats de validation est dû à une probable érosion des pixels autour de zones ayant correctement été identifiées. Cette différence n'étant pas significative, les résultats obtenus à la suite de la classification du filtrage devraient faire l'objet d'un test statistique.

L'intérêt du filtre n'est pas pour autant remis en cause, car la baisse de qualité de la validation est partielle et faible. Les exactitudes de l'utilisateur et du producteur en sont affectées négativement pour certains trimestres, positivement pour d'autres.

Les polygones d'entraînement de la validation proviennent principalement de la couronne agricole autour de Pokola pour la déforestation et de forêt ripicole pour la forêt stable. Une validation basée sur des polygones de provenance plus variée serait probablement impactée positivement, le filtre affectant principalement les zones de forêt stable.

Bien que l'amélioration visuelle soit manifeste, l'application successive de plusieurs filtres spatiaux, avant et après la classification, provoque de la perte d'information.

3) Confrontation des résultats avec la littérature scientifique

En comparant la méthode de ce travail à celle de l'article de Reiche *et al.* (2021), on constate certaines similitudes, mais des résultats finaux différents. Les deux méthodes parviennent à atteindre une résolution temporelle de 90 jours. La résolution spatiale est de 10 mètres pour les 2 méthodes.

Cependant, la zone étudiée dans ce travail est plus petite que celle étudiée dans l'article de Reiche *et al.* (2021). Alors que ce travail se concentre sur la cité de Pokola et ses environs, l'article de Reiche *et al.* (2021) étudie les forêts de l'ensemble du bassin du Congo.

L'article de Reiche *et al.* (2021) exploite les moyennes et les médianes de la rétrodiffusion en polarisation et VH, tandis que ce travail-ci exploite également les quantiles et l'écart-type, ainsi que le ratio des polarisations et la cohérence.

La méthode de classification n'est pas non plus identique. D'une part, il s'agit de classifications par pixel et par objet, entraînées par l'algorithme RF, de l'autre une méthode bayésienne, exploitant les métriques afin d'en extraire un profil de probabilité de perturbation forestière.

La validation s'effectue dans les 2 cas d'une validation par polygones, mais est plus poussée dans l'article de Reiche *et al.* (2021) puisqu'elle est renforcée à l'aide d'images Landsat.

Les exactitudes de l'utilisateur et du producteur issues de la méthodologie de Reiche *et al.* (2021) valent respectivement 97,6 % et 95 % tandis que cette étude produit, pour la classification par objet, des exactitudes de 93,1 % et 36,3 %, et pour la classification par pixel, de 89,8 et 53,8 %. Cependant, la validation n'est pas estimée suffisamment robuste pour représenter l'exactitude du travail.

Enfin, l'essence même de ces deux travaux n'est pas la même. Tandis que Reiche *et al.* (2021) développe une méthodologie d'alerte de perturbation forestière, ce travail s'oriente sur la détection de la déforestation à haute résolution temporelle.

La confrontation des résultats de ce mémoire aux conclusions tirées par Zhang *et al.* (2019) présente des similitudes entre les 2 résultats. Le suivi du changement de couvert boisé dans la savane à l'aide de S1 menait à une surestimation des surfaces boisées. Le même constat peut être effectué dans cette étude, ou l'erreur d'omission dans l'identification de la déforestation était importante. La solution proposée par Zhang *et al.* (2019) pour surmonter, ces erreurs est de combiner l'utilisation de S1 et S2. De plus, l'étude ayant performé de façon plus efficace que ce travail, l'utilisation d'un produit GRD, plutôt qu'un produit SLC pourrait améliorer la performance du modèle.

Atzberger *et al.* (2020) ayant atteint une exactitude générale de 80 % dans le suivi de l'exploitation forestière illégale, sa méthodologie présente du potentiel. En effet, le résultat produit à l'aide de InSAR est légèrement supérieur à celui obtenu dans la classification par pixel, combinant les produits SLC de cohérence et de rétrodiffusion. La méthode InSAR étant plus précise pour la classification des forêts et des surfaces artificialisées, la classification effectuée dans cette étude devrait attribuer plus d'importance aux métriques de cohérence. La combinaison des paramètres d'interférométrie et de rétrodiffusion produit des résultats atteignant une exactitude de 91 % pour la classification des occupations du sol de Atzberg *et al.* (2020). Une meilleure définition de l'importance des métriques dans la classification pourrait donc améliorer les pourcentages d'exactitude générale.

Tanase *et al.* (2019) propose de densifier les séries temporelles des données SAR afin de produire des résultats plus performants. La densification des données est une perspective qui pourrait améliorer les résultats de la méthodologie.

4) Produit final

L'analyse des résultats a été réalisée au préalable uniquement aux alentours de Pokola afin de faciliter la visibilité des résultats. La figure 65 présente le résultat de la classification par objet sur l'ensemble de la zone d'étude. On constate que le filtre a bien éliminé la majorité du bruit et que les zones de déforestation sont situées principalement dans les couronnes agricoles de Pokola et de Mboko, ainsi que le long de nouveaux chemins d'exploitation.





Figure 65 : Produit final issu de la classification par objet

La figure 60 présente le résultat de la classification par pixel, entraînée par l'ensemble des métriques de rétrodiffusion et de cohérence. Cette classification produit les résultats les plus fiables. Elle met en évidence non seulement la déforestation identifiée à l'aide de la classification par objet, mais également certains chemins d'exploitations plus éloignés et peu mis en évidence par la méthode de classification par objet (66.A). Le filtre, majorant la valeur du pixel sur 1 ha, réduit également l'effet poivre et sel qui était présent précédemment.

Bien que l'erreur de classification ait été réduite par le filtrage, certaines surfaces sont identifiées de



façon erronée comme correspondant à de la déforestation (66.B). Il s'agit de forêts ripicoles, dont la signature spectrale est similaire à celle de la déforestation. Malgré un calibrage du modèle axé sur ce type de forêt, dans lequel les polygones de forêt stable étaient tracés, certaines portions de forêts ripicoles restent tout de même identifiées comme de la déforestation.

Figure 66 : Analyse du produit fini de la classification par pixel ; (A) déforestation réelle identifiée, (B) Identification de déforestation erronée.




Figure 67 : Produit final de la classification par pixel

Conclusion et perspectives

La méthodologie présentée dans cette étude présente certaines faiblesses. Plusieurs pistes d'approfondissement existent cependant afin d'améliorer cette méthodologie.

Premièrement, comme cela a été mentionné, l'importance de chaque métrique dans la classification n'a pas été définie manuellement. L'algorithme RF définit la hiérarchie des métriques dans la détection de déforestation en fonction de leur capacité à éliminer l'erreur. Définir une autre hiérarchie d'importance pour les métriques produit des arbres de décisions différents et donc une classification différente, en attribuant notamment plus d'importance aux cohérences. Atzberger *et al.* (2020) ayant identifié le traitement des données InSAR comme une piste pouvant amener à un suivi performant de la déforestation, la littérature scientifique confirme cette perspective d'amélioration. Une analyse approfondie de la hiérarchie des métriques pourrait donc améliorer la méthodologie.

Deuxièmement, la calibration et la validation ayant entraîné le modèle se sont révélées trop orientées sur certaines surfaces. Les polygones de déforestations provenaient principalement de la région périurbaine autour de Pokola, tandis que les polygones de forêt stable provenant essentiellement de forêts ripicoles, celles-ci ayant une signature spectrale semblable à la déforestation et nécessitant un calibrage de forêt stable robuste. Un masque de forêt ripicole permettrait d'échapper à cette calibration axée et ainsi de produire des polygones de calibration et de validation provenant de surfaces plus variées. Ainsi, les exactitudes de l'utilisateur et du producteur des 2 classifications augmenteraient probablement. Une meilleure calibration permettrait également de confirmer par validation l'impact positif du filtre spatial appliqué aux classifications.

Une autre piste à explorer serait d'améliorer la classification par objet de façon à ce qu'elle soit aussi efficace à l'échelle annuelle qu'à l'échelle trimestrielle. Pour cela, le modèle pourrait être entraîné à l'aide des cohérences et des ratios, métriques exclues des classifications par objet par souci d'efficacité. En cas de résultats positifs, la classification par objet serait alors la méthode plébiscitée pour les classifications trimestrielles, aux dépens de la classification par pixel.

L'application de cette même méthodologie sur une autre zone d'étude revisitée plus fréquemment par les satellites S1 permettrait d'obtenir plus de données et de produire des métriques plus robustes. Une zone d'étude visitée par les satellites 1A et 1B ainsi que par les orbites ascendantes et descendantes permettrait de densifier les métriques. De plus, certaines images prélevées durant les 4 années étaient défectueuses sur la zone d'étude de ce mémoire. Des données sélectionnées sur zone d'étude avec un temps de revisite plus élevé et sans images aberrantes produiraient certainement de meilleures classifications trimestrielles.

Une validation des résultats sur le terrain apporterait également une plus-value, notamment pour identifier les coupes partielles, laissant les canopées inférieures intactes et indétectables visuellement sur des images d'optique. En effet, les coupes de régénération sont plus difficiles à détecter, puisque les régions de régénération avancée ne sont pas discernables des forêts matures. Les articles scientifiques comprenant des données de terrain dans leur méthodologie semblent performer sensiblement mieux que les études n'ayant pas réalisé de campagne de terrain (Hoekman *et al.*, 2020).

Une amélioration potentielle du travail serait d'effectuer la même méthodologie avec un produit initial GRD, à la place d'un produit SLC. Ce produit a en effet performé efficacement dans d'autres études (Baumann *et al.*, 2018; Zhang *et al.*, 2019). Cependant, certains auteurs préconisent l'utilisation des produits SLC. En effet, les produits SLC exploitent les informations sur la phase et permettent donc un alignement plus précis des images les unes par rapport aux autres. Les produits SLC possèdent également le même nombre équivalent de regards indépendants (ENL), permettant une meilleure réduction du bruit (Hoekman *et al.*, 2020). Les études utilisant des produits différents ayant performé de manière similaire, le choix du produit le plus approprié s'effectue en fonction de la topographie de la zone d'étude, de son climat et de l'objectif à atteindre.

La revue de la littérature présentée en début de mémoire propose une autre amélioration potentielle du travail, en effectuant à la classification par MLK et non par RF (Erinjery *et al.*, 2018).

Enfin, la piste la plus prometteuse pour améliorer la détection de la déforestation à l'échelle trimestrielle serait d'effectuer la même méthodologie que celle présentée dans l'article de Reiche *et al.* (2021). En effet, ce mémoire s'est inspiré de cette étude et présente donc des similitudes, notamment des résolutions spatiales et temporelles identiques. La méthodologie de Reiche *et al.* performant apparemment de façon plus exacte que ce travail, il serait intéressant d'observer si cette méthodologie est aussi efficace dans la poursuite des objectifs de ce travail.

Ainsi, la classification serait entraînée par un modèle gaussien, dont les métriques calibrent les probabilités de déforestation. Les classifications sont ensuite effectuées sur 2 seuils de probabilités, et non à l'aide de l'algorithme RF.

La validation combine ensuite les pourcentages d'exactitude obtenus à l'aide des polygones de validation à des observations optiques. La confrontation des résultats obtenus par ces classifications aux images Landsat permettrait de valider de façon systématique la classification, en échantillonnant des polygones de validation spécifique aux images Landsat.

Reiche *et al.* exploite les données Landsat en tant que données de validation, mais de nombreux articles proposent également d'exploiter ces données en tant que données d'entraînement. La combinaison des données SAR aux données optiques dans le suivi de changement de couvert est en effet très performant ((Baumann *et al.*, 2018) ; (Liu *et al.*, 2020)).

Les différentes bandes du SAR possédant des propriétés variées, la combinaison des satellites S1 en bande C à d'autres SAR en bande L ou P, auxquels seraient ajoutées des données Landsat en tant que données d'entraînement ou de validation, renforcerait la robustesse des données d'entraînement et produirait les résultats les plus exactes (Rosen *et al.*, 2016).

De nombreuses pistes d'amélioration sont donc envisageables afin d'approfondir les résultats obtenus dans ce travail qui se voulait pionnier.

Ce mémoire s'inscrit dans une thématique largement étudiée par la communauté scientifique, le suivi de la déforestation, et propose un processus de recherche visant à soumettre une nouvelle méthode pour permettre une détection efficace de la déforestation. L'exploitation des satellites S1 dans le cadre du suivi de la déforestation présente des possibilités diverses, ainsi que des capacités spécifiques au SAR.

Les étapes méthodologiques présentées dans ce travail, leur mise en application et l'analyse des résultats auxquels elles ont permis d'aboutir ont permis de tirer certaines conclusions concernant la qualité de la méthodologie ainsi que concernant l'exactitude des résultats.

La classification par objet entraînée par les métriques de rétrodiffusion du satellite S1A permet d'identifier la déforestation annuelle sur une période de 4 ans avec une exactitude générale moyenne de 85,35%. Les classifications annuelles par pixel ont détecté la déforestation de façon légèrement moins précise, atteignant une exactitude générale moyenne de 82,56%. La majorité des surfaces de déforestation détectée étant inférieure à 1 ha, une résolution spatiale élevée est requise. L'acquisition d'images complètes tous les 12 jours à 10m de résolution spatiale a permis de développer un suivi de ces petites zones de déforestation.

Une diminution du pas de temps à une classification trimestrielle a permis d'identifier la déforestation à plus haute résolution temporelle. Cette résolution temporelle élevée s'accompagne d'une perte d'information. Les classifications trimestrielles par pixel permettent ainsi d'identifier la déforestation avec une exactitude de 75,86%, tandis que les classifications trimestrielles par objet fournissent une exactitude générale de 71,64%. L'objectif étant d'identifier la déforestation à haute résolution, la perte de précision spatiale est préférée à une faible résolution temporelle.

L'analyse des résultats indique que les erreurs d'omissions de la déforestation sont plus fréquentes que les erreurs de contamination. La détection de déforestation par cette méthode est donc assurée d'être réellement de la déforestation. Cependant, certaines régions déforestées risquent d'être omises.

Le filtrage des classifications trimestrielles a permis de s'affranchir du bruit issu de ces classifications. Cependant, le filtrage des résultats n'a pas permis d'augmenter la précision de la validation des résultats.

Ces différents résultats illustrent le potentiel de l'exploitation des images S1 dans le suivi de la déforestation résolvant ainsi le problème de la couverture nuageuse importante. Les résultats pourraient cependant encore être améliorés. L'utilisation des images S1 seule s'avère suffisante pour entraîner des classifications binaires forêt/non forêt, mais une consolidation à l'aide de satellites optiques permettrait d'optimiser les résultats obtenus à l'aide des images S1. Une validation combinant l'optique et le SAR fournirait des précisions importantes sur l'exactitude des résultats. Une meilleure maîtrise de l'algorithme de classification permettrait également d'optimiser les résultats. Un autre type de classification ou une autre combinaison des métriques entraînant les modèles de classification pourrait également améliorer la performance du modèle.

La recherche sur le suivi de la déforestation à l'aide de données S1 nécessite encore beaucoup d'approfondissement afin d'exploiter entièrement son potentiel.

Bibliographie

Alternatives Sud (2008) 'Déforestation : causes, acteurs et enjeux', in. Paris.

Atlas forestier du Congo (2019) *Ministère de l'Économie Forestière*. Available at: <https://cog-data.forest-atlas.org/datasets/concessions-forest%C3%A8res-> (Accessed: 4 February 2021).

Atzberger et al. (2020) 'Study on Monitoring of Forests through Remote Sensing'. DG ENVIRONMENT European Parliament.

Baumann, M. et al. (2018) 'Mapping continuous fields of tree and shrub cover across the Gran Chaco using Landsat 8 and Sentinel-1 data', *Remote Sensing of Environment*, 216, pp. 201–211. doi: 10.1016/j.rse.2018.06.044.

Calibrage radiométrique Sentinel-1—ArcGIS Pro | Documentation (no date). Available at: <https://pro.arcgis.com/fr/pro-app/latest/help/analysis/raster-functions/sentinel-1-radiometric-calibration.htm> (Accessed: 12 May 2021).

CBFP (no date) *Congo Basin - CBFP - Congo Basin Forest Partnership*. Available at: <https://pfbc-cbfp.org/congo-basin.html> (Accessed: 30 January 2021).

CIB, Ministère de l'économie forestière et de l'environnement de la République du Congo (2006) 'Inventaire des ressources forestières de l'unité forestière d'aménagement de Pokola (Nord Congo)'.

Clark C.J. and Poulsen J.R., P. (2014) 'Tropical forest conservation & industry partnership: an experience from the Congo', *Ecological Management & Restoration*, 15. doi: 10.1111/emr.12105.

Climate-Data (no date) *Climat Pokola: Pluviométrie et Température moyenne Pokola, diagramme ombrothermique pour Pokola - Climate-Data.org*. Available at: <https://fr.climate-data.org/afrique/congo-brazzaville/sangha/pokola-52835/> (Accessed: 22 March 2021).

COMIFAC (2015) 'Forêts d'Afrique Centrale et changements climatiques – synthèse'.

de Wasseige C., Flynn J., Louppe D., Hiol Hiol F., Mayaux Ph. (2014) *Les forêts du bassin du Congo – État des Forêts 2013*. Weyrich. Belgique. Available at: https://www.observatoire-comifac.net/docs/edf2013/FR/EDF2013_FR.pdf.

Deutscher, J. et al. (2017) 'Humid Tropical Forest Monitoring with Multi-Temporal L-, C- and X-Band SAR Data', in. doi: 10.1109/Multi-Temp.2017.8035264.

Duveiller, G. et al. (2008) 'Deforestation in Central Africa: Estimates at regional, national and landscape levels by advanced processing of systematically-distributed Landsat extracts', *Remote Sensing of Environment*, 112(5), pp. 1969–1981. doi: 10.1016/j.rse.2007.07.026.

Earth Resources Observation And Science (EROS) Center (2017) 'Advanced Very High Resolution Radiometer (AVHRR) 1K'. U.S. Geological Survey. doi: 10.5066/F7K35S5K.

EO Open Science (2019) *Fundamentals about SAR remote sensing - Day 2.1*. Available at: <https://www.youtube.com/watch?v=Fr8H4xOMxq0> (Accessed: 3 February 2021).

EO Open Science (2019) *Sentinel-1 and Sentinel-2 missions and instruments performances - Day 1.5*. Available at: <https://www.youtube.com/watch?v=75VNAZapQt8> (Accessed: 4 February 2021).

- Hamunyela, E. *et al.* (2020) 'Space-time detection of deforestation, forest degradation and regeneration in montane forests of Eastern Tanzania', *International Journal of Applied Earth Observation and Geoinformation*, 88, p. 102063. doi: 10.1016/j.jag.2020.102063.
- Hoekman, D. *et al.* (2020) 'Wide-Area Near-Real-Time Monitoring of Tropical Forest Degradation and Deforestation Using Sentinel-1', *Remote Sensing*, 12(19), p. 3263. doi: 10.3390/rs12193263.
- IMERG (2019) *Precipitation Climatology | NASA Global Precipitation Measurement Mission*. Available at: <https://gpm.nasa.gov/data/imerg/precipitation-climatology> (Accessed: 17 May 2021).
- Jaxa (2020) *About ALOS*. Available at: https://www.eorc.jaxa.jp/ALOS/en/about/about_index.htm (Accessed: 23 November 2020).
- Kaplan, G. and Avdan, U. (2019) 'Evaluating the utilization of the red edge and radar bands from sentinel sensors for wetland classification', *CATENA*, 178, pp. 109–119. doi: 10.1016/j.catena.2019.03.011.
- Kitajima, K., Mulkey, S. S. and Wright, S. J. (1997) 'Seasonal leaf phenotypes in the canopy of a tropical dry forest: photosynthetic characteristics and associated traits', *Oecologia*, 109(4), pp. 490–498. doi: 10.1007/s004420050109.
- Kranz, O. *et al.* (2018) 'Earth observation based multi-scale assessment of logging activities in the Democratic Republic of the Congo', *ISPRS Journal of Photogrammetry and Remote Sensing*, 144, pp. 254–267. doi: 10.1016/j.isprsjprs.2018.07.012.
- Kwarteng, A. Y. *et al.* (2008) 'SAR-based land cover classification of Kuwait', *International Journal of Remote Sensing*, 29(23), pp. 6739–6778. doi: 10.1080/01431160802209097.
- Lambin, E. F. and Ehrlich, D. (1997) 'The identification of tropical deforestation fronts at broad spatial scales', *International Journal of Remote Sensing*, 18(17), pp. 3551–3568. doi: 10.1080/014311697216793.
- Lepers, E. *et al.* (2005) 'A Synthesis of Information on Rapid Land-cover Change for the Period 1981–2000', *BioScience*, 55(2), pp. 115–124. doi: 10.1641/0006-3568(2005)055[0115:ASOIOR]2.0.CO;2.
- Li, W. *et al.* (2020) 'High-resolution mapping of forest canopy height using machine learning by coupling ICESat-2 LiDAR with Sentinel-1, Sentinel-2 and Landsat-8 data', *International Journal of Applied Earth Observation and Geoinformation*, 92, p. 102163. doi: 10.1016/j.jag.2020.102163.
- Li, X. *et al.* (2002) 'An effective content-based visual image retrieval system,' Proceedings 26th Annual International Computer Software and Applications, Oxford, UK, 2002, pp. 914–919, doi: 10.1109/CMPSAC.2002.1045122
- Loew, A. and Mauser, W. (2007) 'Generation of geometrically and radiometrically terrain corrected SAR image products', *Remote Sensing of Environment*, 106, pp. 337–349. doi: 10.1016/j.rse.2006.09.002.
- Löfstedt, T. *et al.* (2019) 'Gray-level invariant Haralick texture features', *PLOS ONE*, 14(2), p. e0212110. doi: 10.1371/journal.pone.0212110.
- Malingreau, J. P. *et al.* (1995) 'AVHRR for global tropical Forest monitoring: The lessons of the TREES project', *Remote Sensing Reviews*, 12(1–2), pp. 29–40. doi: 10.1080/02757259509532273.

Mamat, A. R. *et al.* (2016) 'Average Analysis Method in Selecting Haralick's Texture Features on Color Co-occurrence Matrix for Texture Based Image Retrieval', *International Journal of Multimedia and Ubiquitous Engineering*, p. 10.

Mancon, S. *et al.* (2015) 'Sentinel-1 precise orbit calibration and validation - 2015 Fringe Workshop'. Available at: <http://seom.esa.int/fringe2015/files/presentation330.pdf> (Accessed: 12 May 2021).

Mikwa, J. *et al.* (2016) 'Assessment by remote sensing of forest cover change in a forest region of Kisangani', *International Journal of Innovation and Scientific Research*, 24(2), pp. 255–267.

NASA (2013) *Ice, Cloud, and land Elevation Satellite | NASA's Earth Observing System*. Available at: <https://eosps.gsfc.nasa.gov/missions/ice-cloud-and-land-elevation-satellite> (Accessed: 23 November 2020).

NASA (2020) *MODIS Web*. Available at: <https://modis.gsfc.nasa.gov/about/design.php> (Accessed: 23 November 2020).

Nasirzadehdizaji, R. *et al.* (2021) 'Sentinel-1 interferometric coherence and backscattering analysis for crop monitoring', *Computers and Electronics in Agriculture*, 185, p. 106118. doi: 10.1016/j.compag.2021.106118.

Navarro, J. A. *et al.* (2019) 'Integration of UAV, Sentinel-1, and Sentinel-2 Data for Mangrove Plantation Aboveground Biomass Monitoring in Senegal', *Remote Sensing*, 11(1), p. 77. doi: 10.3390/rs11010077.

Ngo Bieng, M. A. *et al.* (2021) 'Relevance of secondary tropical forest for landscape restoration', *Forest Ecology and Management*, 493, p. 119265. doi: 10.1016/j.foreco.2021.119265.

Nicolau, A. P. *et al.* (2021) 'Assessing SAR C-band data to effectively distinguish modified land uses in a heavily disturbed Amazon forest', *International Journal of Applied Earth Observation and Geoinformation*, 94, p. 102214. doi: 10.1016/j.jag.2020.102214.

OFAC (no date) *Plateforme analytique de l'OFAC*. Available at: https://www.observatoire-comifac.net/analytical_platform (Accessed: 15 February 2021).

OLAM (2016) 'UFA POKOLA PLAN DE GESTION DE L'UFP 3 PERIODE 2017-2021'.

Olam International (no date) *Wood Products, Olam*. Available at: [/content/olamgroup/en/home-page/products-services/olam-international/wood-products](https://content.olamgroup/en/home-page/products-services/olam-international/wood-products) (Accessed: 30 January 2021).

OPITCONGOBRAZZAVILLE (2017) 'POKOLA', *OPIT*, 20 June. Available at: <https://www.officedutourisme.gouv.cg/pokola/> (Accessed: 7 February 2021).

Petrou, Z. I., Manakos, I. and Stathaki, T. (2015) 'Remote sensing for biodiversity monitoring: a review of methods for biodiversity indicator extraction and assessment of progress towards international targets', *Biodiversity and Conservation*, 24(10), pp. 2333–2363. doi: 10.1007/s10531-015-0947-z.

Quegan, S. and Yu, J. (2001) 'Filtering of multichannel SAR images', *Geoscience and Remote Sensing, IEEE Transactions on*, 39, pp. 2373–2379. doi: 10.1109/36.964973.

Reiche, J. *et al.* (2015) 'A Bayesian approach to combine Landsat and ALOS PALSAR time series for near real-time deforestation detection', *Remote Sensing*, 7, pp. 4973–4996. doi: 10.3390/rs70504973.

- Reiche, J. *et al.* (2018a) 'Characterizing Tropical Forest Cover Loss Using Dense Sentinel-1 Data and Active Fire Alerts', *Remote Sensing*, 10. doi: 10.3390/rs10050777.
- Reiche, J. *et al.* (2018b) '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, pp. 147–161. doi: 10.1016/j.rse.2017.10.034.
- Reiche, J. *et al.* (2021) 'Forest disturbance alerts for the Congo Basin using Sentinel-1', *Environmental Research Letters*, 16(2), p. 024005. doi: 10.1088/1748-9326/abd0a8.
- République du Congo : Ministère de l'Économie Forestière et du Développement Durable, OLAM, CIB (2006) 'Résumé du plan d'aménagement de l'Unité Forestière d'Aménagement de Pokola'.
- Rodríguez, E. *et al.* (2006) 'A Global Assessment of the SRTM Performance', *Photogrammetric Engineering & Remote Sensing*, 72(3), pp. 249–260. doi: 10.14358/PERS.72.3.249.
- Rosen, P. *et al.*: "An update on the NASA-ISRO dual-frequency DBF SAR (NISAR) mission", Proceedings of the IEEE International Geoscience and Remote Sensing Symposium (IGARSS), Beijing, China, 2016
- Rüetschi *et al.* (2017) 'Using Multitemporal Sentinel-1 C-band Backscatter to Monitor Phenology and Classify Deciduous and Coniferous Forests in Northern Switzerland', *Remote Sensing*, 10(2), p. 55. doi: 10.3390/rs10010055.
- Sasaki, N. *et al.* (2021) 'Predicting carbon emissions, emissions reductions, and carbon removal due to deforestation and plantation forests in Southeast Asia', *Journal of Cleaner Production*, p. 127728. doi: 10.1016/j.jclepro.2021.127728.
- Sica, F. *et al.* (2019) 'Repeat-pass SAR interferometry for land cover classification: A methodology using Sentinel-1 Short-Time-Series', *Remote Sensing of Environment*, 232, p. 111277. doi: 10.1016/j.rse.2019.111277.
- Suppression de bruit thermique Sentinel-1—ArcGIS Pro | Documentation* (no date). Available at: <https://pro.arcgis.com/fr/pro-app/latest/help/analysis/raster-functions/sentinel-1-thermal-noise-removal.htm> (Accessed: 12 May 2021).
- Suspense Averti Ifo, Stoffenne Binsangou. (2019) 'Variabilité spatiale du stock de carbone de la biomasse aérienne de la zone urbaine vers la forêt tropicale dense dans cinq localités de la république du Congo', in.
- Tanase, M. A. *et al.* (2019) 'Synthetic aperture radar sensitivity to forest changes: A simulations-based study for the Romanian forests', *Science of The Total Environment*, 689, pp. 1104–1114. doi: 10.1016/j.scitotenv.2019.06.494.
- University of Maryland (no date) *Global Forest Change*. Available at: https://earthenginepartners.appspot.com/science-2013-global-forest/download_v1.5.html (Accessed: 22 March 2021).
- USGS (2016) *Landsat Missions : Landsat 8*. Open-File Report. Available at: https://www.usgs.gov/core-science-systems/nli/landsat/landsat-8?qt-science_support_page_related_con=0#qt-science_support_page_related_con (Accessed: 22 November 2020).
- Vancutsem, C. *et al.*, (2021) *Long-term (1990–2019) monitoring of forest cover changes in the humid tropics | Science Advances*. Available at: <https://advances.sciencemag.org/content/7/10/eabe1603> (Accessed: 12 May 2021).

Van Pham, M. *et al.* (2019) 'Integrating Sentinel-1A SAR data and GIS to estimate aboveground biomass and carbon accumulation for tropical forest types in Thuan Chau district, Vietnam', *Remote Sensing Applications: Society and Environment*, 14, pp. 148–157. doi: 10.1016/j.rsase.2019.03.003.

Wildenborg, F. (2021) *Wageningen Climate Solutions (EN) - Radar satellite exposes illegal logging in African rainforests*. Available at: <https://magazines.wur.nl/climate-solutions-en/radar-satellite-exposes-illegal-logging-in-african-rainforests/> (Accessed: 3 February 2021).

World Bank (2004) 'Sustaining Forests : A Development Strategy'. Washington, DC. Available at: <https://openknowledge.worldbank.org/handle/10986/14951> License: CC BY 3.0 IGO." (Accessed: 27 October 2020).

Simone Mancon, Politecnico di Milano *et al.* (2015) 'Sentinel-1 precise orbit calibration and validation - 2015 Fringe Workshop'. Available at: <http://seom.esa.int/fringe2015/files/presentation330.pdf> (Accessed: 12 May 2021).

WRI (no date) *Global Forest Watch, World Resources Institute*. Available at: <https://www.wri.org/initiatives/global-forest-watch> (Accessed: 5 June 2021).

Zhang, D. *et al.* (2020) 'The reference data for accuracy assessment of the Global Forest Watch tree cover 2000 in China', *Data in Brief*, 29, p. 105238. doi: 10.1016/j.dib.2020.105238.

Zhang, W. *et al.* (2019) 'From woody cover to woody canopies: How Sentinel-1 and Sentinel-2 data advance the mapping of woody plants in savannas', *Remote Sensing of Environment*, 234, p. 111465. doi: 10.1016/j.rse.2019.111465.

Annexes

Table des figures

FIGURE 1 : EVOLUTION DU SIGNAL DE RETRODIFFUSION EN POLARISATION VH SUR DES SURFACES STABLES SUR 4 ANS.....	II
FIGURE 2 : CHANGEMENT DU COUVERT FORESTIER ANNUEL DE 2017 ISSU D'UNE CLASSIFICATION PAR PIXEL	III
FIGURE 3 : CHANGEMENT DU COUVERT FORESTIER TRIMESTRIEL DE 2017 ISSU D'UNE CLASSIFICATION PAR PIXEL	III
FIGURE 4 : CHANGEMENT DU COUVERT FORESTIER ANNUEL DE 2018 ISSU D'UNE CLASSIFICATION PAR PIXEL	IV
FIGURE 5 : CHANGEMENT DU COUVERT FORESTIER TRIMESTRIEL DE 2018 ISSU D'UNE CLASSIFICATION PAR PIXEL	IV
FIGURE 6 : CHANGEMENT DU COUVERT FORESTIER ANNUEL DE 2020 ISSU D'UNE CLASSIFICATION PAR PIXEL	V
FIGURE 7 : CHANGEMENT DU COUVERT FORESTIER TRIMESTRIEL DE 2020 ISSU D'UNE CLASSIFICATION PAR PIXEL	V
FIGURE 8 : CHANGEMENT DU COUVERT FORESTIER ANNUEL DE 2017 ISSU D'UNE CLASSIFICATION PAR OBJET	VI
FIGURE 9 : CHANGEMENT DU COUVERT FORESTIER TRIMESTRIEL DE 2017 ISSU D'UNE CLASSIFICATION PAR OBJET	VI
FIGURE 10 : CHANGEMENT DU COUVERT FORESTIER ANNUEL DE 2018 ISSU D'UNE CLASSIFICATION PAR OBJET	VII
FIGURE 11 : CHANGEMENT DU COUVERT FORESTIER TRIMESTRIEL DE 2018 ISSU D'UNE CLASSIFICATION PAR OBJET	VII
FIGURE 12 : CHANGEMENT DU COUVERT FORESTIER ANNUEL DE 2020 ISSU D'UNE CLASSIFICATION PAR OBJET	VII
FIGURE 13 : CHANGEMENT DU COUVERT FORESTIER TRIMESTRIEL DE 2020 ISSU D'UNE CLASSIFICATION PAR OBJET	VII
FIGURE 14 : TABLEAU DES PERFORMANCES DES CLASSIFICATIONS ET DU NOMBRE DE POLYGONES ET DE PIXELS DE CALIBRATION ET DE VALIDATION.....	IX

1) Rétrodiffusion sur 4 ans sur des surfaces stables en polarisation VH




Figure 1 : évolution du signal de rétrodiffusion en polarisation VH sur des surfaces stables sur 4 ans

2) Classifications

a) Par pixel




Figure 2 : changement du couvert forestier annuel de 2017 issu d'une classification par pixel




Figure 3 : changement du couvert forestier trimestriel de 2017 issu d'une classification par pixel




Figure 4 : changement du couvert forestier annuel de 2018 issu d'une classification par pixel




Figure 5 : changement du couvert forestier trimestriel de 2018 issu d'une classification par pixel




Figure 6 : changement du couvert forestier annuel de 2020 issu d'une classification par pixel




Figure 7 : changement du couvert forestier trimestriel de 2020 issu d'une classification par pixel

b) Par objet




Figure 8 : changement du couvert forestier annuel de 2017 issu d'une classification par objet




Figure 9 : changement du couvert forestier trimestriel de 2017 issu d'une classification par objet




Figure 10 : changement du couvert forestier annuel de 2018 issu d'une classification par objet




Figure 11 : changement du couvert forestier trimestriel de 2018 issu d'une classification par objet




Figure 12 : changement du couvert forestier annuel de 2020 issu d'une classification par objet




Figure 13 : changement du couvert forestier trimestriel de 2020 issu d'une classification par objet

3) Tableau des performances des classifications et du nombre de polygones et de pixels de calibration et de validation

/	Exactitude générale des classifications par pixel	Exactitude générale des classifications par objet	Classification par pixel				Classification par objet			
			N polygones		N pixels		N polygones		N pixels	
			cal	val	cal	val	cal	val	cal	val
T201701	77,76%	59,18%	41	27	7429	1646	488	36	39058	2129
T201702	89,88%	73,02%	44	22	6075	484	496	68	39719	3877
T201703	82,11%	70,09%	89	31	15619	475	487	45	39024	2671
T201704	77,45%	56,19%	41	31	3251	368	492	38	39476	2506
T201801	48,16%	64,22%	43	34	3089	434	261	38	20374	2180
T201802	67,83%	61,03%	26	23	3994	400	255	23	20081	1619
T201803	83,35%	69,17%	34	20	4513	850	255	24	20049	1852
T201804	64,71%	60,78%	28	19	5916	279	254	19	20067	1183
T201901	81,02%	87,21%	25	28	7010	627	216	23	17850	1423
T201902	96,20%	96,54%	34	52	3756	1106	231	23	19185	1474
T201903	97,20%	97,52%	55	41	5439	1073	236	56	19486	5160
T201904	92,59%	75,71%	34	10	4628	189	229	51	19124	3396
T202001	64,29%	59,34%	37	28	5623	98	192	21	15984	1537
T202002	53,91%	85,58%	44	22	3347	1039	193	20	16219	1415
T202003	45,11%	71,01%	57	23	4347	134	187	26	15101	1735
T202004	94,82%	59,59%	30	19	3113	251	197	24	16141	1606

Figure 14 : Tableau des performances des classifications et du nombre de polygones et de pixels de calibration et de validation

Suivi de la déforestation tropicale à l'aide des données SAR en bande C du satellite Sentinel-1A

Aline DENIS

Résumé

Le bassin du Congo représente l'une des plus grandes surfaces forestières au monde. Les forêts de la République du Congo appartiennent à cet immense massif forestier et font donc partie d'une région écologiquement et socioéconomiquement importante, qui doit être protégée. La protection et l'entretien de ces forêts permettent le maintien de fonctions écosystémiques majeures.

Étant donné les rôles indispensables associés à la forêt, la recherche liée au suivi de la déforestation est abondante. Dans le cadre de la télédétection en particulier, les données de nombreux radars et capteurs optiques ont servi à détecter la déforestation. L'analyse de la littérature scientifique met en évidence l'utilité des capteurs optiques, mais également leurs limitations. Dans ce travail, il s'agira d'approfondir l'utilisation du SAR en bande C afin de détecter la déforestation. Sentinel-1 permettrait de suppléer les limitations de l'optique et ainsi de fournir un suivi de la déforestation à haute résolution temporelle et spatiale, indépendamment de la couverture nuageuse.

La République du Congo subit des épisodes de déforestation à travers l'entièreté de son territoire, mais dans le cadre de ce travail, il est important de se limiter à une zone de taille réduite dans laquelle la déforestation est particulièrement intense. C'est ainsi que le choix de la zone d'étude s'est porté sur les environs de la ville de Pokola, zone entourée de concessions forestières subissant des épisodes de déforestation fréquents.

Ce travail présente donc une méthodologie complète ayant pour objectif de produire un suivi de la déforestation à haute résolution spatiale et temporelle. Cette méthodologie comprend la sélection des données satellites, le traitement et l'analyse de ces données, ainsi que la production de classifications du couvert forestier/non forestier. Ce travail devrait être amélioré à l'aide d'une méthode de calibration plus robuste et par des données de terrain.