



HAL
open science

Méthodes de cartographie et analyses des impacts de l'exploitation forestière par LiDAR aéroporté en Guyane

Xavier Klee

► **To cite this version:**

Xavier Klee. Méthodes de cartographie et analyses des impacts de l'exploitation forestière par LiDAR aéroporté en Guyane. Géographie. 2024. dumas-04723333

HAL Id: dumas-04723333

<https://dumas.ccsd.cnrs.fr/dumas-04723333v1>

Submitted on 7 Oct 2024

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

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

MASTER 2

Domaines : Sciences Humaines et Sociales – Sciences Technologies Santé
Mention Géographie, Aménagement, Environnement et Développement

Parcours GEOSPHERES :

Méthodes de cartographie et analyses des
impacts de l'exploitation forestière par LiDAR
aéroporté en Guyane

Stage réalisé au pôle RDI de l'ONF Guyane

Mémoire soutenu le : 3 septembre 2024

devant un jury composé de :

Pauline Dusseux

Maitresse de Conférence, PACTE, Université Grenoble Alpes

Franck Giazzi

Enseignant-Chercheur, PACTE, Université Grenoble Alpes

Caroline Bedeau

Chargée de recherche et développement, RDI, ONF Guyane

Klee Xavier
M2 GEOSPHERES
ANNEE 2023-2024

Etablissements partenaires :

Remerciement

En premier lieu, je tiens à remercier Caroline Bedeau de m'avoir fait confiance en acceptant de me prendre comme stagiaire. Un grand merci pour m'avoir permis de découvrir le monde de la forêt équatoriale et d'avoir pris le temps de commenter mes travaux. Sans cela, ce mémoire n'aurait résolument pas la même allure. Je vous suis reconnaissant de m'avoir offert une certaine liberté quant aux choix des méthodes utilisées.

Merci à Pauline Dusseux d'avoir accepté d'être mon enseignant référent et d'avoir accepté de commenter la construction de mon mémoire. Merci à Franck Giazzi d'avoir accepté de faire partie de mon jury.

Merci à Jeremy, Carla, Thomas, Alexandre et tous les autres du pôle RDI et du pôle pistes pour votre bienveillance et votre bonne humeur. Une mention spéciale pour Thomas Gaquiere qui m'a beaucoup conseillé dans le choix des démarches statistiques.

Merci à Fabian Fischer pour les quelques échanges qui m'ont permis de mieux appréhender sa méthode de construction des modèles de canopée et d'avoir accepté de me partager son code R. Merci aussi à Dorian Martinetto pour avoir accepté d'organiser une réunion en ligne afin de me conseiller pour la construction de l'U-Net.

Je tiens à remercier mes parents et mes sœurs. En somme, merci à ma famille pour votre soutien et votre capacité à être toujours là quand il faut. Je tiens particulièrement à remercier ma mère, Christine, pour avoir pris le temps de relire ce manuscrit en apportant un regard extérieur.

Merci à Jérôme, Tara, Mathilde, Jacques, Marie et tous les autres. J'ai été surpris de remarquer que votre joie et votre humour peuvent, apparemment, traverser l'Atlantique. Il est toujours génial d'écouter vos histoires, aussi absurdes et étranges sont-elles.

Résumé

L'exploitation forestière occupe une place importante dans le paysage guyanais. Elle est un véritable moteur économique pour le département guyanais. Toutefois, une telle activité n'est pas sans impact pour l'environnement. Forcément l'exploitation forestière dégrade la forêt. Afin de limiter les impacts de l'exploitation forestière, l'Office National des Forêts demande aux compagnies exploitantes de respecter une charte d'exploitation, à savoir la charte d'exploitation à faible impact ou EFI. Cependant, du fait des temps importants de régénération de la forêt guyanaise, les impacts de l'EFI sur la forêt ne sont pas encore tout à fait compris.

Ainsi, ce mémoire se propose de manipuler des données LiDAR multitudes afin d'essayer de mettre en lumière les effets de l'EFI sur la forêt guyanaise. Cela passe par la mise en place d'une méthodologie solide pour parvenir à quantifier les impacts de l'EFI. Au passage, nous en profiterons pour comparer différentes méthodes de modélisation de la canopée et nous plonger dans l'élaboration d'une méthode performante pour l'extraction du réseau de desserte par apprentissage profond. Au terme de la démarche méthodologique, il a été décidé d'analyser par la statistique exploratoire un jeu de données traduisant les impacts de l'exploitation, l'intensité de l'exploitation et les conditions de la forêt de préexploitation.

Les analyses montrent que l'EFI influence significativement la structure forestière, notamment en réduisant la hauteur de la canopée et en augmentant son ouverture. Le nombre d'arbres coupés et le pourcentage de l'emprise de la desserte contribuent à ces modifications. L'état initial de la forêt ne semble pas influencer les impacts observés, qui dépendent principalement des interventions humaines. Cependant, une variabilité importante entre les exploitants rend difficile la généralisation des impacts de l'EFI, soulignant la nécessité d'approches adaptées pour une gestion durable des forêts en Guyane française.

Table des Matières

Liste des abréviations	5
Introduction	6
1 La forêt guyanaise et la télédétection LiDAR pour quantifier les impacts de l'EFI	8
1.1 Description générique de la forêt guyanaise et aperçu de la diversité de ses fonctions	8
1.2 Genèse et caractérisation des objectifs de l'exploitation à faibles impacts	9
1.3 Intérêt de la télédétection pour l'étude et la gestion de la forêt tropicale	10
1.4 Utilisation du LiDAR pour la cartographie du sol et de la desserte forestière	12
1.5 Utilisation du LiDAR pour la cartographie de la couverture forestière	13
2 Présentation des zones d'études et des données utilisées	15
2.1 Présentation de l'agencement des parcelles forestières	15
2.2 Présentation des données traitées	16
3 Construction de modèles numériques pour l'étude de la forêt.	17
3.1 Paramètre de génération des MNT et des RDM	17
3.2 Évaluation et sélection de la méthode de CHM en fonction de la sensibilité à la dégradation de la densité de pulses	18
4 Cartographie de la desserte forestière par segmentation d'image	20
4.1 Génération d'une visualisation des microtopographies comme entrée de l'U-net 3+	21
4.2 Caractéristiques internes du modèle U-Net 3+ produit pour la segmentation du réseau de desserte	23
4.3 Analyse de la qualité de la segmentation de la desserte forestière par U-Net 3+	25
5 Création de variables pour l'étude des impacts de l'EFI et analyses statistiques exploratoires	27
5.1 Mise en valeur des impacts de l'exploitation forestière par la création de variables	27
5.2 Démarche statistique pour l'exploration des impacts de l'EFI	30
6 Analyses statistiques pour la quantification des impacts de l'EFI	31
6.1 Analyse bivariée	31
6.2 Analyse exploratoire des relations multivariées	33
6.3 Impacts de l'exploitation à la canopée selon l'exploitant	34
7 Discussion et perspectives	36
Conclusion	38
Bibliographie	40
Annexes	45

Liste des figures

Figure 1) Représentation schématique des différences entre les types de données captées par les capteurs optiques, les capteurs Pol-SAR et les capteurs ALS. _____	11
Figure 2) Organisation des UP et du réseau de desserte dans une parcelle forestière _____	15
Figure 3) Carte de localisation des parcelles et de la disponibilité des données sur les arbres abattus _____	16
Figure 4) Évolution de la qualité des différents types de CHM en fonction de la dégradation de la densité de pulses _____	19
Figure 5) Morphologie des différents types de routes et de pistes du réseau de desserte forestière. _	21
Figure 6) Comparaison de la visualisation de pistes entre une LRM SAILORE amplifié et un LRM simple. _____	22
Figure 7) Représentation schématique du modèle U-net 3+ utilisée pour la segmentation de la desserte forestière. _____	23
Figure 8) Résumé de l'évolution des métriques et de la perte du modèle au cours de l'entraînement.	25
Figure 9) Comparaison entre les pistes déclarées par l'exploitant et les pistes détectées par la segmentation _____	26
Figure 10) Carte des variables extraites depuis le traitement des données LiDAR _____	29
Figure 11) Matrice des corrélations entre les variables étudiées _____	32
Figure 12) Représentation graphique de la spatialisation des variables et des individus sur les deux premières dimensions de l'ACP _____	33
Figure 13) Modélisation de la moyenne ajustée pour le pourcentage d'ouverture de la canopée en fonction de l'exploitant _____	35
Figure 14) Modélisation de la moyenne ajustée pour la variation de la hauteur de la canopée en fonction de l'exploitant _____	35

Liste des abréviations

ACP : Analyse en composante principale

AIC : *Akaike Information Criterion*

ALS : *Airborne Laser Scanning*

CHM : *Canopy height model*

CNN : *Convolutional neural network*

DFP : Domaine forestier permanent

EFI : Exploitation faible impact

EMM : *Estimated marginal mean*

GPS : *Global Positioning System*

IoU : *Intersect over Union*

LiDAR : *Light Detection And Ranging*

LRM : *Local Relief Model*

MNT : Modèle Numérique de Terrain

ONF : Office National des Forêt

PEFC : *Pan European Forest Certification*

RDM : *Relative Density Model*

SAILORE : *Self-Adaptive Local Relief Enhancer*

TIN : *Triangular Irregular Networks*

UP : Unité de Prospection

Introduction

Dans « *La rivière Vincent Pinzon* », le géographe français Vidal de la Blache relate la découverte de la Guyane par l'explorateur Vincent Yanez Pinzon qui devient, en 1500, le premier européen à approcher les côtes de cette région. Après quoi, en 1529, le cartographe espagnol Diego Ribero déclare « *Non a allado cosa de provecho* » (il n'y a rien d'utile là), reléguant hâtivement la Guyane au statut de terre sans intérêt. Quel manque de considération du cartographe pour la terre qui abrite au centre du lac sacré imaginaire *Guatavita* la cité légendaire de *Manua*, *El Dorado*, la fantastique cité d'or ! À présent, après 495 ans, malgré l'échec de la quête pour *El Dorado*, la Guyane nous a légué des ressources et des trésors qui continuent de réfuter l'affirmation de Diego Ribero. La Guyane abrite une portion de la forêt équatoriale d'Amazonie, une forêt considérée comme une formation écologique d'une richesse et d'une importance primordiale pour le vivant. Comment imaginer le monde sans cette vaste étendue de végétation, dont la densité impénétrable lui a longtemps valu le surnom « d'enfer vert ». Aujourd'hui, du fait de la crise climatique et du déclin de la biodiversité, la préservation de l'Amazonie devient encore plus cruciale. Quid de la libération du carbone qu'elle renferme si tout son bois venait à brûler ? Quid de l'existante future de la flore et des autres créatures qu'elle héberge si toutes les niches finissent rasées ? Deux questions ouvertes dont les conséquences des énoncés peuvent provoquer une angoisse certaine. Toutefois, malgré les risques que comprend la dégradation de la forêt amazonienne, elle cache des ressources dont l'exploitation est devenue nécessaire pour le maintien du confort des populations locales. Ici, nous nous intéresserons au sujet de la sylviculture dans le territoire de la Guyane française. Dans cette région équinoxiale, la sylviculture est gérée par l'office national des forêts (ONF) qui délivre des droits d'exploitation à des sociétés tierces. L'ONF définit donc le paradigme dans lequel les méthodes d'exploitation doivent s'insérer. Soucieux de la bonne santé de la forêt équatoriale pour des raisons écologiques et économiques, l'office demande aux exploitants de suivre une exploitation à faibles impacts (EFI). Toutefois, en raison de l'échelle de temps multidécennale de la régénération de la forêt, les impacts de l'EFI sur la forêt ne sont pas tout à fait compris. Ainsi, il est du devoir du pôle de Recherche Développement et Innovation (RDI) de l'ONF de documenter au mieux les impacts de l'EFI sur la forêt guyanaise. En conséquence, dans un tel contexte, ce mémoire tente de comprendre et de mesurer les impacts de l'exploitation à faibles impacts sur la structure des forêts exploitées de la Guyane française.

Durant ce développement, il sera question d'approfondir la compréhension des impacts de l'EFI sur les forêts exploitées de la Guyane. Ce mémoire se propose d'examiner les effets de l'EFI sur la structure de la forêt sur la base d'exploitation de données LiDAR (Light Detection And Ranging)

aéroporté collecté avant et après exploitation. Ainsi, nous explorerons aussi l'intérêt de l'optimisation des méthodes de productions et d'analyses de données issues de LiDAR, pour mesurer au mieux les forêts exploitées de Guyane.

Le manuscrit se décompose en 6 parties.

La première partie est dédiée à une présentation de la forêt équatoriale guyanaise et de ses fonctions. Nous y verrons ensuite l'intérêt de la télédétection pour son étude et notamment la télédétection par LiDAR aéroporté. Nous traiterons de l'utilisation du LiDAR pour la cartographie des réseaux de desserte, du sous-bois et de la canopée. Nous passerons rapidement sur les complications méthodologiques liées à l'utilisation du LiDAR pour de l'analyse diachronique.

Une deuxième partie est allouée à une présentation très succincte de l'organisation spatiale des zones d'études. Puis nous explorerons les données utilisées et leur qualité.

Une troisième partie est dédiée à la construction des modèles numériques utilisés pour produire et extraire les données nécessaires au bon déroulement de l'étude. Nous porterons une attention particulière à la modélisation de la canopée en testant plusieurs méthodes de modélisation de la canopée.

Dans une quatrième partie, nous concentrerons sur l'extraction du réseau de la desserte forestière en concevant un modèle de segmentation par apprentissage profond, à savoir : un modèle U-Net 3+. Pour ce faire, nous utiliserons une méthode de visualisation des microtopographies spécialement adaptée aux topographies complexes.

Une cinquième partie permettra de détailler les variables extraites depuis les modèles numériques conçus à lors de la partie 3 et du réseau de desserte segmenter dans la partie 4. Nous créerons un jeu de données qui regroupe les parcelles forestières traitées. Le jeu de données regroupera des variables décrivant les impacts de l'exploitation forestière, l'intensité de l'exploitation forestière et les conditions initiales de la forêt d'avant exploitation.

Enfin, une ultime partie sera allouée au développement de l'analyse statistique pour l'identification des impacts de l'EFI sur la structure forestière. Cela passera par réalisation d'une analyse statistique exploratoire.

1 La forêt guyanaise et la télédétection LiDAR pour quantifier les impacts de l'EFI

1.1 Description générique de la forêt guyanaise et aperçu de la diversité de ses fonctions

La forêt guyanaise recouvre 96% du territoire guyanais, en valeur absolue cela représente une surface de plus ou moins 8 millions d'hectares. Ce territoire d'une taille semblable à l'Autriche est coïncé entre les 2e et 6e degrés de latitude Nord. Du fait de sa situation géographique, la forêt de Guyane est située en milieu équatorial, où le climat éponyme est marqué par une alternance de saisons des pluies et de saisons sèches, selon les divagations de la zone de convergence intertropicale. Le climat y est chaud et très humide. Forte de ses caractéristiques climatiques, la forêt de Guyane admet un macro-écosystème qui la range dans la catégorie des forêts décidues humides tropicales et subtropicales. Ces forêts se caractérisent par une haute canopée dense et fermée, le sous-bois y est aussi très dense. La fermeture de la canopée rend la pénétration de la lumière à travers les houppiers difficile, la faible quantité de lumière pénétrant le sous-bois bénéficie au développement d'espèces ombrophiles. À l'instar de toutes les forêts de la bande équatoriale, la forêt guyanaise abrite en son sein une flore et une faune d'une diversité formidable. La 17e version du référentiel taxonomique pour la France (TAXREF) considère que la Guyane abrite près de 1599 espèces endémiques contre 6380 espèces endémiques pour tout le territoire français (Gargominy et al. 2022). Cependant, en raison de l'isolement de la forêt guyanaise, ce chiffre sous-estime grandement le nombre réel d'espèces (Thonnell, Sant, et Brisse 2023).

Par ailleurs, la forêt guyanaise est peu marquée par les activités anthropiques. En 2014, il était considéré que 90% de la forêt guyanaise pouvait être considéré comme forêt primaire ou ancienne (FAO 2014). Pourtant, la forêt guyanaise est aussi la scène d'exploitation de ressources naturelles : son sous-sol pour les ressources minières et la forêt pour la ressource sylvicole. L'exploitation du bois est à 99,4% gérée par l'Office National des Forêts (ONF) et se concentre dans la zone du domaine forestier permanent (DFP).

Dans ces cas, on comprend aisément le rôle de la forêt pour la préservation de la biodiversité et le développement économique des populations attelées à son exploitation. La forêt est aussi bien une réserve naturelle qu'un moteur économique. En 2014, la sylviculture représentait le troisième secteur d'activité, assuré par 900 emplois directs, ce secteur représentait 60 millions d'euros de chiffre

d'affaires (INSEE 2014). Les grumes dont la qualité est conforme sont principalement destinées au commerce local tandis que les grumes non conformes ou les déchets de l'exploitation se voient considérés comme bois d'énergie. Par ailleurs, dans le cadre du changement climatique, nous allouons à la forêt guyanaise un nouveau rôle, celui de régulateur et de stockage du carbone atmosphérique (Coomes et al. 2008).

1.2 Genèse et caractérisation des objectifs de l'exploitation à faibles impacts

Aujourd'hui, afin de lutter contre le réchauffement climatique, de nombreux Etats cherchent à réduire leur empreinte carbone liée à l'exploitation de matières premières. La sylviculture ne fait pas exception. Il est estimé qu'entre 2005 et 2010, l'exploitation des forêts tropicales représentait une émission de 1,1 milliard de tonnes de dioxyde de carbone par an (Pearson et al. 2017). Ainsi, en 2008, le programme UN-REDD renforce la nécessité de réduire l'empreinte carbone des exploitations forestières en milieu tropical (Duchelle et al. 2018). Pour ce faire, il existe plusieurs modes d'exploitation pouvant être considérés comme durables, on parle de mise en place d'exploitation à faible impact (EFI). L'EFI a l'avantage d'être plus conciliante envers la biodiversité (Bicknell, Struebig, et Davies 2015) et de réduire les émissions de carbone dans l'atmosphère (Ellis et al. 2019; Putz et al. 2008). L'utilité de l'EFI dans la réduction de la dégradation de la structure forestière est déjà démontrée (Asner, Keller, et Silva 2004; Pereira et al. 2002) mais ne bénéficie pas d'un large panel d'étude sur le sujet. Bien qu'exprimés pour la première fois en 1993 (Putz et Pinard 1993), les impacts de l'EFI sont encore peu étudiés étant donné les temps multidécennaux de la régénération des forêts tropicales.

En Guyane française, la généralisation de l'EFI se fait par l'ONF, cette dernière a la capacité de contraindre la récolte et les méthodes d'extraction du bois sur le domaine forestier permanent. L'exploitation du bois guyanais se doit de respecter la certification du *Program for Endorsement of Forest Certification schemes* (PEFC), cette certification peut uniquement être allouée aux exploitations forestières respectant une charte EFI (Direction Territoriale de l'ONF Guyane 2017). Cette charte assure une gestion durable de l'exploitation des forêts sur l'essentiel de ces étapes. Par exemple, cela passe notamment par la limitation des impacts à la canopée en s'assurant de prélever moins de 5 individus par hectare, en préservant les individus d'intérêt pour la régénération de la forêt et en proposant un réseau de pistes dont la superficie est inférieure à 8% de la surface exploitable de chaque parcelle.

Cependant, pour que l'ONF puisse s'assurer de proposer du bois répondant au critère de la certification PEFC, il est nécessaire de s'assurer du respect des conditions d'exploitation imposées par la charte EFI. Ce contrôle de la qualité des exploitations forestières a un effet double, il permet de veiller au respect de la charte EFI et de quantifier les impacts de l'EFI sur l'évolution des parcelles forestières. L'étude des impacts de l'EFI permet d'améliorer la compréhension des dynamiques prenant place dans les forêts exploitées afin d'optimiser la durabilité de leur exploitation.

1.3 Intérêt de la télédétection pour l'étude et la gestion de la forêt tropicale

Les forêts tropicales humides sont des milieux particulièrement difficiles à étudier du fait de leur taille, de leur isolement et de leur encombrement. La mise en place de suivis exhaustifs de la forêt par mesure *in situ* est particulièrement difficile à assumer, c'est là une méthode très coûteuse en temps et en argent. De ce fait, il est difficile d'étudier leur évolution de manière exhaustive sans passer par des méthodes orientées télédétection (Chambers et al. 2007 ; Fuller 2006; Sader 1990). Le développement de la télédétection aéroportée, ou spatioportée a été une petite révolution pour l'étude des forêts tropicales. Cependant, il faut tout de même reconnaître qu'il est peu probable que la télédétection permette d'acquérir des données dont la qualité équivaut aux mesures *in situ* (Mulatu et al. 2017). Ainsi, souvent, il demeure important de considérer les données de terrain pour corriger les biais ou les imprécisions existant dans les données issues de télédétection.

Parmi les types de capteurs disponibles, on retrouve en premier lieu les capteurs optiques. Les capteurs optiques excellent dans la caractérisation des modes d'occupation du sol ou pour déduire l'état sanitaire de la canopée. Toutefois, ils sont bridés du fait de la grande nébulosité des régions tropicales (Nazarova, Martin, et Giuliani 2020). Au problème de la nébulosité viennent les capteurs radar. Ils proposent sensiblement le même panel d'application que les capteurs optiques (Dupuis et al. 2020). Ils demeurent assez performants pour le suivi des forêts tropicales (Ballere 2021), mais souffrent aussi des perturbations météorologiques et représentent un type de données plus difficile à traiter. Une ultime catégorie, celle que ce mémoire traite, est dédiée aux capteurs LiDAR. Les techniques de télédétection optique et radar fonctionnent sur la base de technologie différente, mais renvoient une image où la surface de l'environnement est caractérisée par la valeur d'un pixel, de cela, le LiDAR se distingue tout à fait. Le LiDAR émet un laser, qui vient traverser l'atmosphère et le couvert végétal en renvoyant un retour pour chaque entité qui intercepte partiellement la zone de l'empreinte du laser (Lim et al. 2003). Dans ce mémoire, pour qualifier les laser émis nous utiliserons le terme anglais *pulses*. En sortie

d'un relevé LiDAR, la donnée n'est pas une image, mais un nuage de points où chaque point est une interception du pulse. À chaque point est attribué un ensemble de données relatif à sa position (x,y,z), son intensité ou encore son numéro de retour (ASPR 2019). La précision d'une étude par LiDAR dépend partiellement du nombre de pulses par mètres carrés. Dans le contexte de l'exploitation forestière, on devine assez vite que l'intérêt du LiDAR réside dans sa capacité à pouvoir cartographier la structure verticale d'un massif forestier, du sol à la canopée (fig. 1).

Différence d'informations captées entre des capteurs optiques, Pol-SAR et ALS en milieu tropical humide

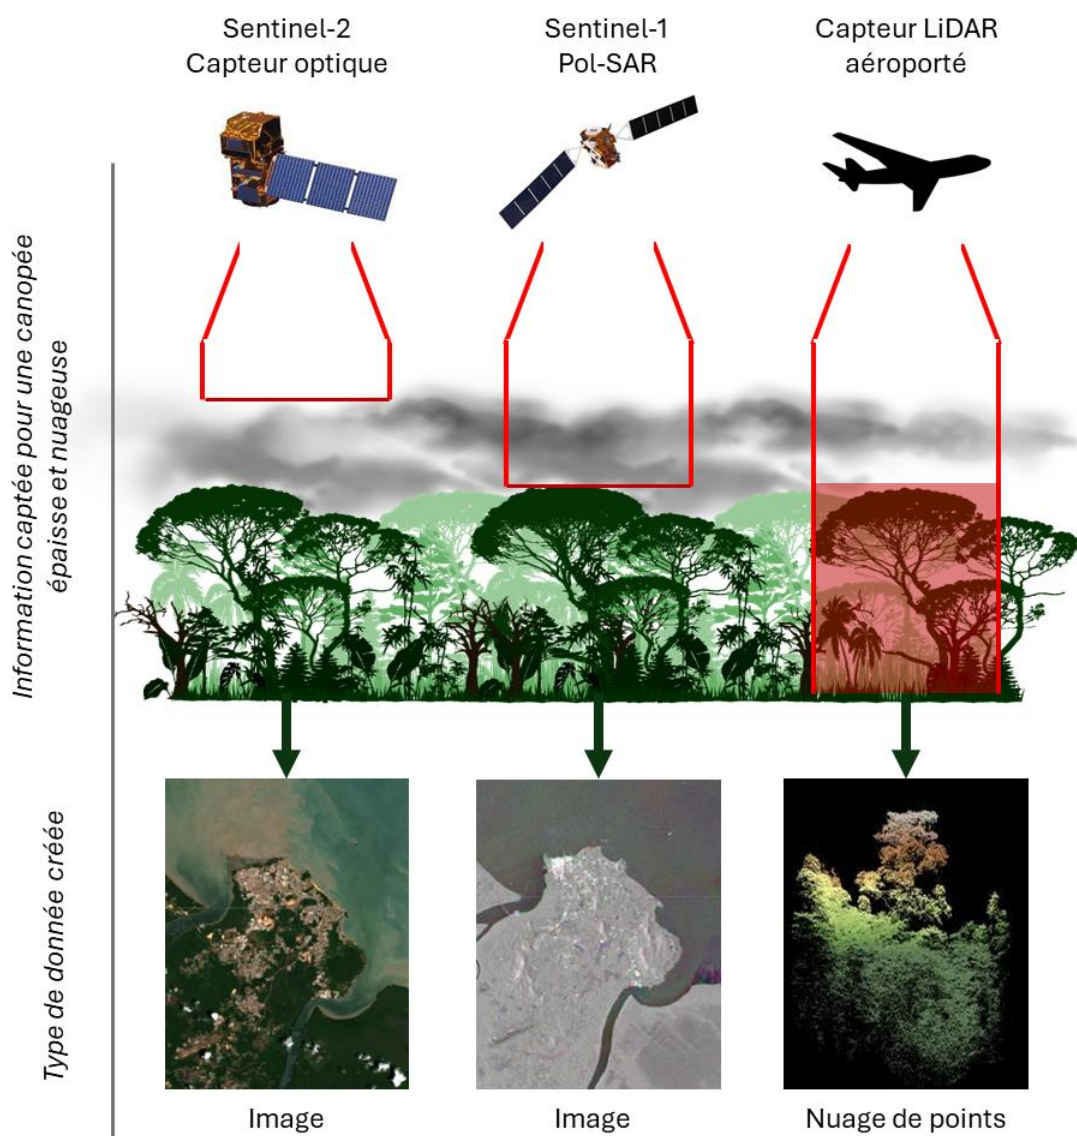


Figure 1) Représentation schématique des différences entre les types de données captées par les capteurs optiques, les capteurs Pol-SAR et les capteurs ALS. Pol-SAR se réfère aux capteurs radar.

1.4 Utilisation du LiDAR pour la cartographie du sol et de la desserte forestière

Dans un nuage de point LiDAR, il est possible d'appliquer une classification des points par type d'entité. Au minimum, cette étape permet de déterminer les points sol. Étant donné que chaque point admet des coordonnées x y et z , il devient possible de modéliser des modèles numériques de terrain (MNT). Pour ce faire, il suffit de générer un modèle numérique par une interpolation. Il existe une pléthore de modèle d'interpolation, du plus simple comme le TIN, à des méthodes plus complexes comme le krigeage ou l'utilisation de splines (Arun 2013; Štular, Lozić, et Eichert 2023). Il est important de considérer que même si les méthodes d'interpolation complexe proposent généralement de meilleurs résultats, elles sont généralement plus coûteuses en temps de calcul. Par ailleurs, il est aussi important de noter que la qualité du MNT produit sera fonction de la densité de points sol enregistrés dans notre nuage de points. Ainsi, il est peu pertinent de proposer des modèles numériques dont la résolution de l'image est inférieure à l'espacement moyen des points du nuage.

Pour étudier une exploitation forestière depuis un MNT il est possible d'extraire de nombreuses métriques comme les caractéristiques topologiques ou le réseau des pistes de débardage. L'extraction du réseau de desserte repose généralement sur l'exploitation de MNT et des dérivés premiers de MNT (pente, ombrage, rugosité, etc). Certains proposent de digitaliser manuellement le réseau de desserte afin que la connaissance de l'opérateur permette de rendre compte de la pertinence du tracé (Affek et al. 2017). Malheureusement, au vu de la taille et du nombre de parcelle que traite l'ONF Guyane, la digitalisation manuelle peut ne pas toujours être considérée comme l'issue la plus efficace. Il peut être nécessaire de se tourner vers des classifications semi-automatiques utilisant des méthodes de *machine learning* (Ferraz et al. 2016; Sherba, Blesius, et Davis 2014). Ces méthodes semblent efficaces, mais semblent réservées à des zones où la topographie est très spécifique, souvent en pente. Cela limite leur utilisation hors des régions montagneuses. Il est aussi possible de définir les réseaux de pistes en confrontant des MNT et leurs dérivés avec des données optiques de haute résolution (Buján et al. 2021). Cette méthode a l'air particulièrement efficace et permet de proposer une classification de la desserte. Toutefois elle a le désavantage de demander obligatoirement des données spectrales de haute résolution et nécessite la mise en place d'une lourde chaîne de traitement. De manière plus originale, il est possible d'extraire un réseau de pistes théoriques en cherchant à créer des couches de conductivité sur la base de l'exploitation de multiples métriques issues de données LiDAR (Roussel et al. 2022, 2023). Bien qu'incapable de catégoriser la desserte forestière, cette méthode ne se base que sur des données LiDAR, et est efficace, peu importe le type de terrain. Cependant, selon les données

LiDAR, elle a tendance à générer des sorties très bruitées qui peuvent gêner l'extraction du réseau de desserte. Enfin, les méthodes de segmentation d'image par *deep learning* permettent aussi de cartographier la desserte forestière (Abdi, Uusitalo, et Kivinen 2022; Bienz et Freuler 2022). Les méthodes héritées du *deep learning* ont le désavantage de reposer sur la mise en place de modèle boîte noire dont les paramètres sont difficiles à cerner et très coûteux à entraîner. Pourtant elles se révèlent très performantes et peuvent s'adapter à n'importe quel type de région. Bien que très opaque, ce genre de modèle est relativement facile à mettre en place si l'on dispose d'assez de puissance informatique. La grande flexibilité de la segmentation par *deep learning* permet tout à fait d'appliquer ce genre de modèle pour la cartographie de la desserte forestière en territoire guyanais.

1.5 Utilisation du LiDAR pour la cartographie de la couverture forestière

L'extraction d'un arbre ne se faisant pas sans abimer les individus environnants. La chute de l'arbre, le débusquage au câble et la manipulation des grumes sont autant d'évènements qui peuvent altérer la structure d'une forêt. Dans ce contexte, un des grands intérêts de l'utilisation des nuages de point en foresterie est relatif à la capacité à étudier les points associés au couvert végétal. L'étude du couvert par lidar se fait depuis des nuages de point normalisés. C'est-à-dire, un nuage de points dont on soustrait l'altitude du sol à la coordonnée z des points. Ainsi, on obtient un nuage de points traduisant la hauteur de la végétation. De là, il devient possible d'étudier la structure d'une forêt sans être perturbé par les effets d'altitude liés à l'irrégularité de la topographie. Cela est nécessaire pour cartographier des indicateurs qui rendent compte des impacts de l'exploitation forestière. Un nuage de points normalisé peut aussi bien rendre compte de l'état de la canopée que de l'état du sous-bois (Coops et al. 2021).

Pour étudier la canopée, il est préférable d'utiliser des modèles numériques de canopée (CHM). À la manière des MNT, il existe une multitude de manières de construire des CHM. Ces méthodes sont plus ou moins complexes. La méthode la plus basique consiste à attribuer à chaque pixel du CHM la hauteur du point le plus haut qui intercepte l'emprise du pixel. Ce type de méthode admet des temps de traitement court et renvoie uniquement des valeurs observées. Si les données LiDAR ont une densité d'émission faible, cette méthode a tendance à renvoyer de nombreux pixels sans valeur. Aussi, quand la couverture forestière se désépaissit, cette méthode peut considérer des points sous la canopée. Cela a tendance à manifester des « puits », qui constitue du bruit dans les CHM. Les méthodes plus sophistiquées se basent sur des logiques d'interpolation des points. Tout d'abord, la méthode TIN

consiste, comme pour le MNT, en la réalisation d'une triangulation de Delaunay sur les points les plus hauts des nuages. Cette méthode reste rapide à déployer et ne propose pas de pixel sans valeur. Toutefois, elle reste sensible au problème lié aux « puits ». Pour régler ce problème de « puits », les méthodes Pitfree (Khosravipour et al. 2014) et Spikefree (Khosravipour, Skidmore, et Isenburg 2016) ont été développées. Ces méthodes ont des fonctionnements complexes qui ne seront pas détaillés ici. Il est important de retenir que ces deux dernières méthodes permettent de corriger les bruits liés à ces fameux « puits ».

Quant à lui, le sous-bois est plus complexe à étudier, son étude ne se base pas sur l'emploi d'un CHM, mais sur un modèle de densité relative (RDM) (d'Oliveira et al. 2012; Rangel Pinagé et al. 2019). Pour faire simple, en milieu tropical, le RDM est le nombre de points inférieur à 1 mètre sur le nombre de points inférieurs à 6 mètres. Cela revient à définir l'encombrement du sous-bois. Il est probable que la manipulation des arbres abattus ait un fort impact sur l'encombrement du sous-bois. Bien qu'un pareil indice soit très intéressant à cartographier son usage admet beaucoup de limites. En effet, pour une bonne cartographie du sous-bois, il est nécessaire de capitaliser sur la capacité du LiDAR à traverser la canopée. Ainsi, quand la canopée est trop épaisse ou que la densité de pulses du LiDAR est trop faible, la cartographie du sous-bois par RDM a tendance à devenir lacunaire.

Lors de comparaison diachronique, la différence des capteurs et les différents paramètres d'acquisition conduisent à produire des nuages de points de qualité variable. Les paramètres apportant de la variabilité sont notamment : la densité de pulses émis, l'angle de scan et la hauteur de vol du capteur (Hopkinson 2007). Fatalement, de tels changements influent sur la qualité des CHM produits (Fradette et al. 2019; Holmgren, Nilsson, et Olsson 2003; Roussel et al. 2017). De ce fait, pour comparer de données LiDAR de qualité différente, il est nécessaire de dégrader la qualité du meilleur nuage de points en fonction du nuage ayant la moins bonne qualité.

2 Présentation des zones d'études et des données utilisées

2.1 Présentation de l'agencement des parcelles forestières

Cette étude est conduite sur plusieurs parcelles forestières dont l'ONF Guyane possède des données LiDAR pré et post-exploitation. Cela représente 24 parcelles réparties sur le DFP de Guyane (fig. 2), pour une surface couvrant environ 9,5 km² de forêt ou 950 hectares. Bien que les parcelles soient disséminées à travers tout le DFP, l'essentiel des parcelles se situe dans l'extrémité est du DFP. La topographie des parcelles est très similaire, le relief est toujours collinéen et de très faible altitude (< 200 mètres). Ces formes topographiques sont héritées de la dissection du bouclier des Guyanes. Les sommets des collines sont plutôt plats et elles sont séparées par des zones plates de bas-fond. Dans la plupart des cas, les bas-fonds sont traversés par des cours d'eau. Au sein de chaque parcelle, l'exploitation est réalisée uniquement dans des zones appelées unité de prospection (UP). Les UP se situent sur les reliefs des parcelles, hors des bas-fonds et où la pente est inférieure à 22%. Après

Organisation d'une parcelle forestière
Parcelle : MAN 445

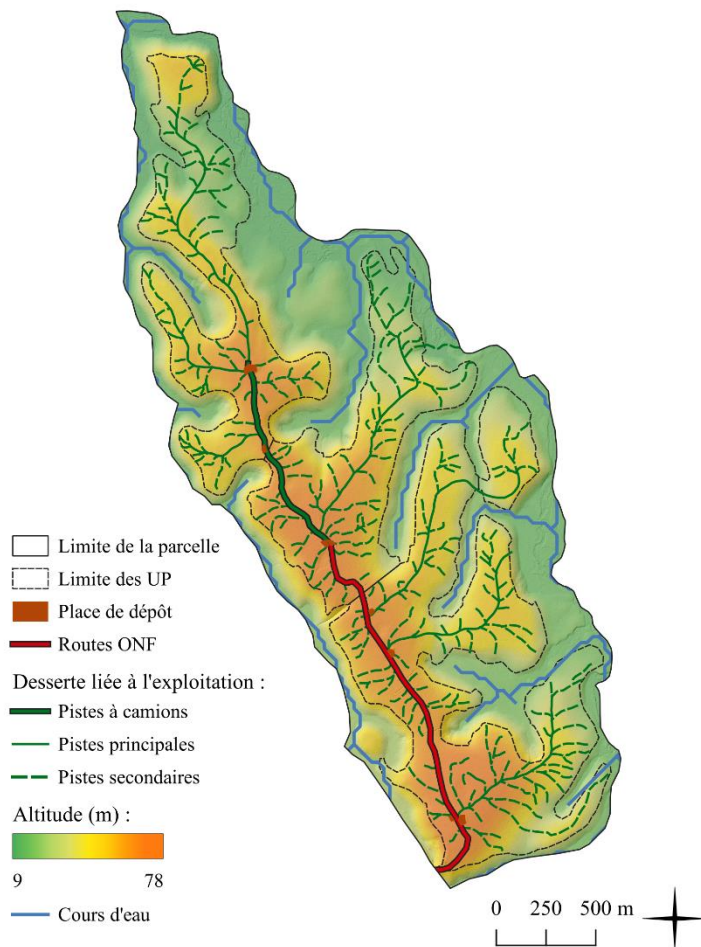


Figure 2) Organisation des UP et du réseau de desserte dans une parcelle forestière

exploitation, les parcelles sont marquées par la mise en place d'un réseau de desserte forestière qui permet aux exploitants de récupérer les bois abattus. Ce réseau admet une typologie de pistes et de routes qui se distinguent en fonction de leur forme et de leurs usages. De manière succincte, dans le réseau de desserte, on distingue les routes ONF qui permettent l'accès aux parcelles, les pistes à camions empruntées par des grumiers pour relier les places de dépôt aux routes ONF, ainsi que les pistes principales et secondaires qui forment le réseau des pistes d'abattage. Ces dernières parcourent l'ensemble de la surface des UP des parcelles et sont utilisées par des véhicules spécifiques, tels que les skidders.

2.2 Présentation des données traitées

Les acquisitions LiDAR sont réalisées par les entreprises ALTOA et SINTEGRA. Les données fournies sont des données LiDAR discret multiretour enregistrées par des capteurs RIEGL de modèle LMS puis VQ. Les entreprises prennent en charge le prétraitement des données dont les nuages de points sont déjà classés et les points aberrants sont pratiquement tous supprimés. Les acquisitions LiDAR ont été faites de 2012 à 2023 avec des densités de pulses allant de 5 p/m² à 52 p/m². Pour chaque parcelle, les données LiDAR sont distribuées avec leur équivalent normalisé. Pour garder une certaine cohérence temporelle entre les différentes acquisitions LiDAR post exploitation, les données ont été collecté globalement 1 ans après la fin de l'exploitation forestière.

Pour compléter les données LiDAR nous disposons de données terrains issues de diagnostics de suivi de forêt en postexploitation. Cela permet de connaitre le nom de l'exploitant et la modalité d'EFI pour chaque UP. Nous avons aussi la position des arbres abattus lors de l'exploitation. Cependant, étant donnée la qualité des données concernant les arbres abattus, cette donnée ne peut être utilisée que pour 6 parcelles (fig. 3).

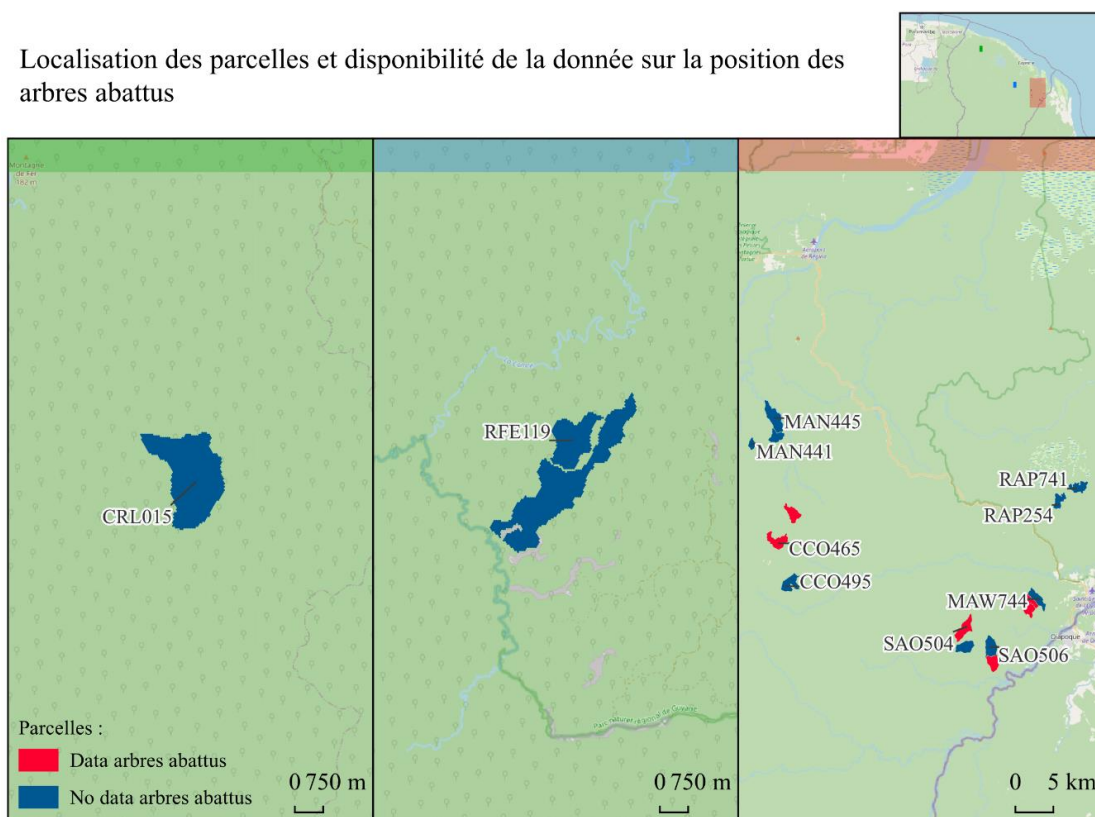


Figure 3) Carte de localisation des parcelles et de la disponibilité des données sur les arbres abattus

3 Construction de modèles numériques pour l'étude de la forêt.

Du fait du caractère diachronique de notre étude, il est nécessaire de générer des séries de modèles numériques depuis les nuages de points. Pour chaque parcelle, deux séries de modèles numériques sont générées, une pour les données de préexploitation et l'autre pour les données post-exploitation, à terme cela permettra d'extraire des variables issues de la comparaison des modèles pré et post exploitation. Chaque série comprend respectivement un modèle numérique de terrain (MNT), un modèle numérique de canopée (CHM) et un modèle de densité relative (RDM). Les modèles numériques sont produits à une résolution spatiale de 1 m x 1 m par pixel. Étant donné que les capteurs utilisés pour produire les données post-exploitation admettent souvent une émission de pulses plus importante que les capteurs de préexploitation, il est impératif de baisser artificiellement la densité de pulses des données post-exploitation. Ainsi, nous pouvons comparer les données de préexploitation avec des données postexploitation en limitant les biais induis par la variation des paramètres d'acquisition. Ainsi, bien que cette dégradation volontaire de la donnée soit frustrante, elle est nécessaire pour s'assurer de comparer des modèles numériques de qualité semblable. Cette réduction est effectuée en supprimant aléatoirement la proportion excédentaire de premiers retours des données post-exploitation par rapport aux données de préexploitation. Ensuite, les points associés aux premiers retours supprimés sont également éliminés.

Afin de garantir un traitement performant des nuages de points LiDAR, nous utilisons les algorithmes de LAStools que nous appelons via des commandes R. Étant écrits en C++, un langage compilé donc rapide à exécuter, LAStools admet des temps de calcul moins longs que les bibliothèques R dédiés au traitement de données ALS.

3.1 Paramètre de génération des MNT et des RDM

Le premier type de modèle numérique généré est le MNT. Il est simplement généré par une interpolation TIN des points classés comme sol. La génération de RDM est permise par l'utilisation de nuages de points normalisés. Ici, la conception des RDM respecte la méthode mise en place en 2012 par d'Oliveira et al. Cela renvoie un modèle numérique dont la valeur est comprise entre 0 et 1, que nous multiplions par 100 pour une interprétation plus intuitive. Une valeur de 100 représente un sous-bois dégagé, alors qu'une valeur de 0 reflète un sous-bois dont l'encombrement est maximal.

3.2 Évaluation et sélection de la méthode de CHM en fonction de la sensibilité à la dégradation de la densité de pulses

Au vu du caractère central qu'occupe la canopée dans cette étude, il est nécessaire de s'assurer d'utiliser la méthode de génération de CHM la plus adaptée à nos besoins. L'analyse diachronique dont ce mémoire fait l'objet présuppose de comparer des données LiDAR pré et post exploitation acquises avec des densités de pulses très variables. Par exemple, pour la parcelle CCO 495, les données pré exploitation ont une densité de pulses globale de 5.55 p/m² contre 52.62 p/m² pour les données post exploitation. Il devient donc nécessaire de tester la sensibilité des méthodes de génération de CHM à la dégradation de la densité de pulses, pour proposer à terme des comparaisons fidèles entre les CHM. Ici, nous nous intéresserons aux méthodes de génération de CHM suivantes : Highest, TIN, Pitfree, Spikefree, T Spikefree et L Spikefree (Fischer et al. 2024). T Spikefree et L Spikefree sont des dérivées de Spikefree. T Spikefree (T pour "thin") consiste à amincir le nuage de points pour limiter les données traitées par Spikefree. L Spikefree (L pour "locally") est une amélioration de Spikefree qui considère l'hétérogénéité spatiale de la densité de pulses dans le nuage LiDAR. Cela permet d'adapter localement les paramètres de l'interpolation Spikefree.

Les six méthodes de CHM ont été générées à cinq niveaux de densité de pulses (p/m²), respectivement : 25, 15, 7, 2,5 et 1 p/m². La densité de 25 p/m² est considérée comme suffisamment élevée pour servir de référence, elle est comparée aux densités inférieures (fig. 4) pour évaluer la dégradation de la justesse des CHM. Le comportement de chaque méthode face à la dégradation des pulses est très variable. Le passage de 25 p/m² à 7 p/m² n'a pas de réelles conséquences pour les méthodes Highest, TIN, T Spikefree et L Spikefree. Seules les méthodes Spikefree et Pitfree semblent perturbées par cette dégradation. Naturellement, à mesure que la densité de pulses diminue, les méthodes de génération des CHM deviennent de moins en moins précises. Les comparaisons entre les CHM de 25 p/m² et ceux de 2,5 p/m² révèlent la sensibilité des méthodes des CHM à la dégradation des pulses. La méthode Highest est la plus sensible à cette dégradation, ayant tendance à associer la valeur de certains pixels à des points situés sous la canopée (Annexe 1). Ces observations montrent qu'à haute densité de pulses, la meilleure méthode pour générer des CHM est la méthode Highest, avec une RMSE inférieure à 1,5 m pour la comparaison entre 25 p/m² et 15 p/m². Entre 7 p/m² et 2,5 p/m², la précision des CHM issus de Highest commence à se dégrader plus nettement. À 7 p/m², Highest se situe derrière L Spikefree et T Spikefree avec un R² de 0,95 et une RMSE de 2,1 m. En dessous de 2,5 p/m², Highest devient une méthode peu précise pour construire un CHM, avec un R² de 0,84 et une RMSE de 4,9 m.

Evolution de la précision des types de CHM en fonction de la densité de pulses

Données : CCO495, 2021 | Echantillon : 10% des pixels

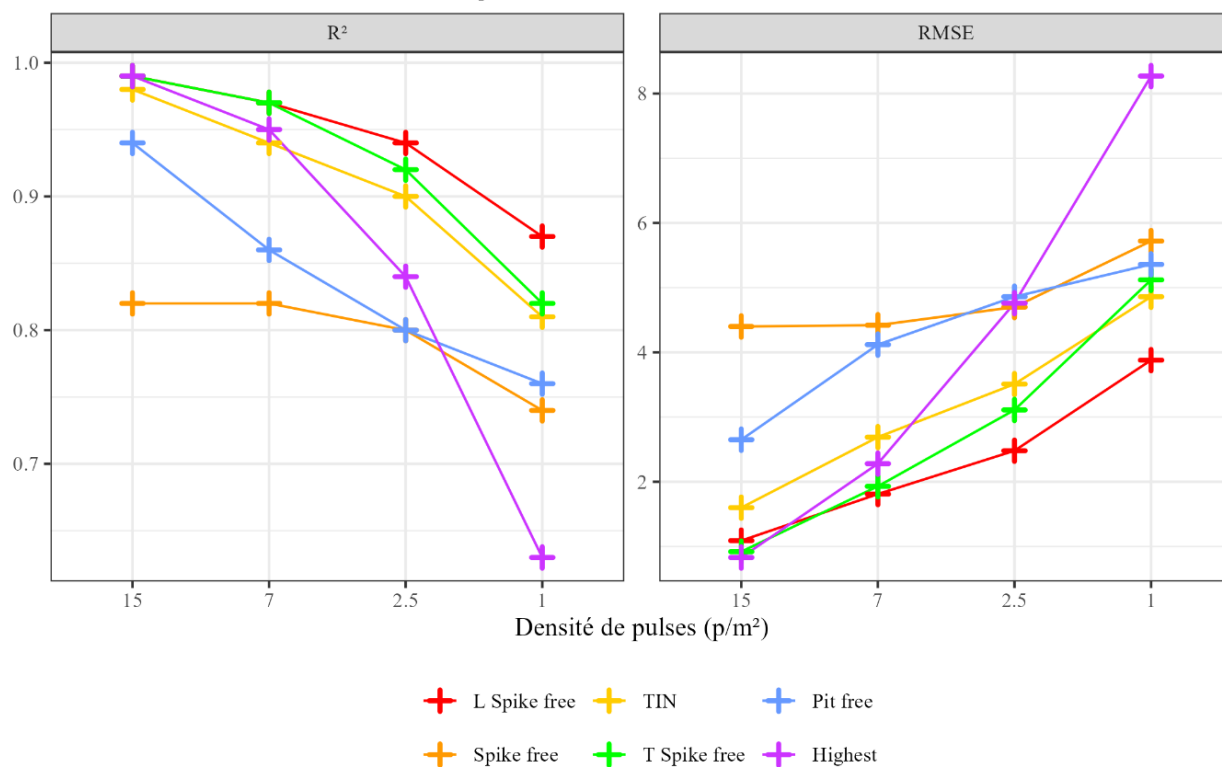


Figure 4) Évolutions de la qualité des différents types de CHM en fonction de la dégradation de la densité de pulses. Le R² et la RMSE sous obtenus en comparant les CHM de moins de 25 p/m² avec un CHM de 25 p/m².

Bien que T Spikefree, L Spikefree et TIN proposent de très bons résultats, Highest a l'avantage de renvoyer des valeurs de hauteur observées et de rester très convenable pour des densités de pulses supérieures à 2,5 p/m². Bien sûr, Highest se montre aussi être une méthode très fragile pour des densités de pulses inférieures à 2,5 p/m². Cependant, dans notre cas, les données utilisées ont une densité de pulses globale supérieure à 5 p/m². Un autre point, plus pratique, en faveur de Highest est la facilité de la mise en œuvre. La création de CHM issue de Highest peut être directement réalisée en utilisant LAStools. À l'inverse, la génération de CHM issue de T Spikefree, L Spikefree demande une mise en place complexe et des temps de traitement plus longs. Au vu des résultats, nous choisissons Highest comme la méthode de génération de CHM la plus pertinente pour cette étude.

4 Cartographie de la desserte forestière par segmentation d'image

Maintenant que nous avons généré les modèles numériques du sol à la canopée, nous pouvons commencer par générer des couches qui traduisent véritablement les impacts de l'exploitation forestière. Ici, nous nous attardons sur une méthode de génération du réseau de desserte pour l'extraction de données relatives à la desserte forestière.

La mise en place d'un pareil réseau est responsable de très forts impacts sur la structure de la forêt. L'ouverture de pistes demande de dégager la végétation du sous-bois et d'abattre les arbres qui gênent le tracé des futures pistes. Cela peut provoquer une ouverture de la canopée plus ou moins importante selon le type de voie de desserte. Ainsi, pour caractériser les impacts de l'exploitation forestière, il est crucial d'avoir accès à une bonne cartographie du réseau de la desserte forestière. Les compagnies exploitantes sont chargées de tracer et de mettre en place le réseau de piste de débardage. Ces données sont accessibles sous format vectoriel, mais proposent une qualité trop variable selon les exploitants. Certains tracés sont exploitables tandis que d'autres n'existent pas. Pour remédier à ce problème, cette partie propose de cartographier la desserte forestière pour garantir une qualité de données plus ou moins similaire entre les différentes parcelles. Pour ce faire, il a été décidé de mettre au point un modèle de segmentation d'image par réseau de neurones à convolution de type U-Net (Ronneberger, Fischer, et Brox 2015). Le choix de cette méthode a été principalement motivé par l'étude des méthodes d'extraction du réseau de la desserte. Cette méthode est performante et très flexible du moment que le réseau de piste peut-être efficacement visualisé. Ici, nous avons choisi spécifiquement un modèle U-Net 3+ (Huang et al. 2020) qui est une architecture améliorée du modèle U-Net. Le fonctionnement des modèles type U-Net est inspiré des CNN (*Convolutional Neural Network*) de LeCun (LeCun, Bengio, et Hinton 2015) et est détaillé dans l'annexe 2. Le modèle est conçu de sorte à être capable de proposer une segmentation multiclassée du réseau de desserte en admettant trois classes : la première est une classe d'arrière-plan qui cartographie l'absence du réseau, la deuxième sert à cartographier les routes ONF et les pistes à camions, la troisième sert à cartographier les pistes de débardage principales et secondaires (fig. 5).



Figure 5) Assemblage de photos illustrant la morphologie des différents types de routes et de pistes du réseau de la desserte forestière. Les zones rouges permettent de mieux visualiser les zones de roulement. A) Piste à camions ; B) et C) Pistes principales ; D) Pistes secondaires

4.1 Génération d'une visualisation des microtopographies comme entrée de l'U-net 3+

Pour segmenter le réseau de desserte, il est impératif de fournir à notre modèle des images permettant de visualiser efficacement les microtopographies de chaque parcelle. La circulation des engins de chantier induit des déformations du sol plus ou moins fortes (creusement du sol pouvant aller jusqu'à l'orniérage). Pour visualiser ces traces, nous générons pour chaque parcelle un modèle de relief local (en anglais : *Local Relief Model* ; LRM) (Hesse 2010). Ce type de représentation du sol consiste à mettre en valeur les aspérités du sol en appliquant un filtre passe-haut sur un MNT. En règle générale, pour visualiser les aspérités du sol en région plane, il est préférable d'utiliser un kernel large

dans le filtre passe-haut. À l'inverse, les zones en pente nécessitent des kernels de taille plus petite pour contrer la forte variabilité de la topographie des pentes.

Dans notre cas, les zones d'étude présentent des topographies complexes, avec des parties planes et d'autres en pente. Ainsi, le LRM généré est inspiré par le LRM SAILORE (Toumazet, Simon, et Mayoral 2021). Cette méthode de génération de LRM permet d'adapter localement la taille du kernel du filtre passe-haut en fonction des variations de pente. Les microtopographies sont mises en valeur avec une taille de kernel toujours optimale pour leur situation dans la topographie globale. Elles bénéficient d'une adaptation locale de la taille du kernel du LRM. Pour améliorer encore le LRM SAILORE, ce dernier est multiplié par un RDM pour augmenter le signal des microtopographies dues au réseau de desserte (fig. 6). Cela est possible, car dans la plupart des cas, le RDM est élevé dans les zones traversées par le réseau de desserte.

Comparaison entre un LRM SAILORE amplifié et un LRM simple




Figure 6) Comparaison de la visualisation de pistes entre une LRM SAILORE amplifié et un LRM simple. Le LRM simple est généré en utilisant le plugin QGIS *Relief Visualization Toolbox* développé par l'université de Ljubljana.

4.2 Caractéristiques internes du modèle U-Net 3+ produit pour la segmentation du réseau de desserte

Maintenant que nous avons les données à traiter par notre modèle, nous pouvons explorer l'anatomie du modèle U-Net 3+ utilisé (fig. 7). Le modèle a été écrit en R en utilisant les bibliothèques de *deep learning* Keras (Kalinowski, Falbel, Allaire, Chollet, et al. 2024) et TensorFlow (Allaire et al. 2024). Une explication succincte du fonctionnement des réseaux U-Net est disponible à l'annexe 2.

Représentation schématique du modèle U-net 3+ utilisé

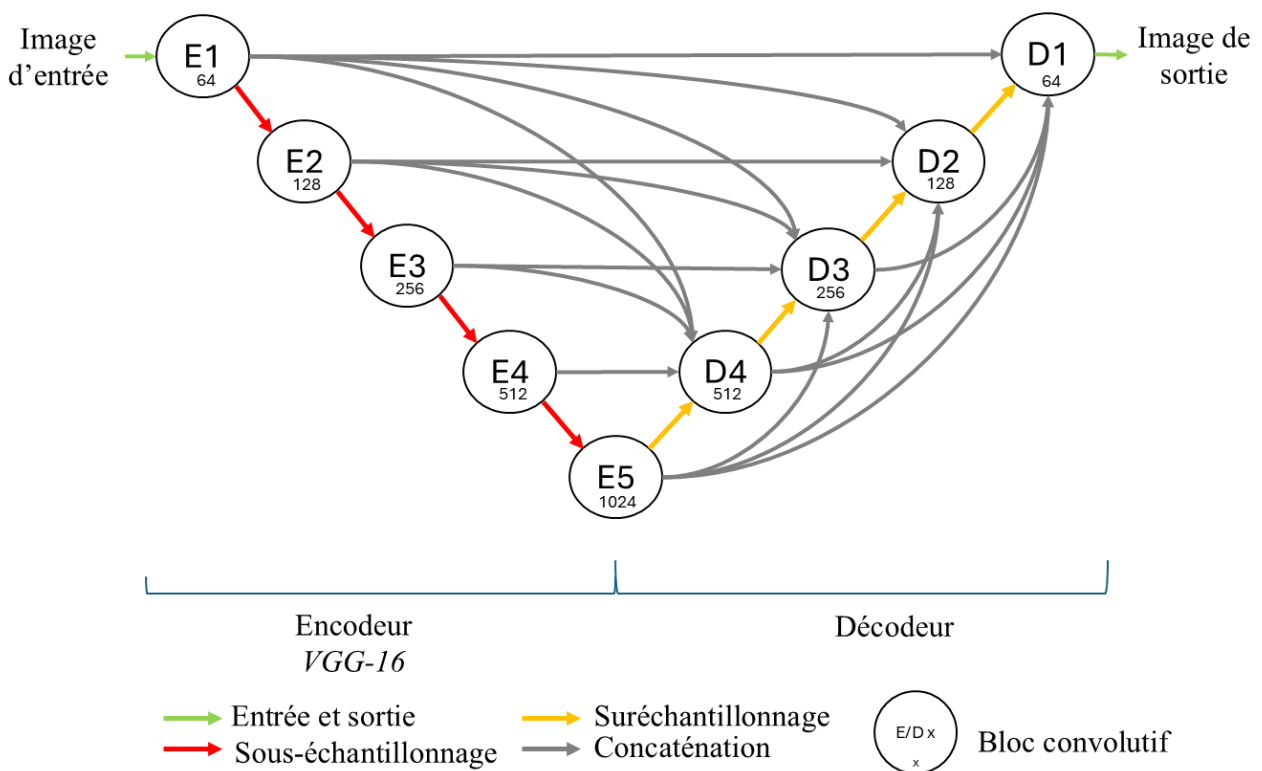


Figure 7) Représentation schématique du modèle U-net 3+ utilisée pour la segmentation de la desserte forestière. Dans les cercles, les lettres E ou D représente respectivement si le bloc fait partie de l'encodeur ou du décodeur. Le chiffre qui suit les lettres E et D représente la profondeur du bloc convolutif associé. Le nombre dans la partie inférieure des cercles représente le nombre de convolutions réalisées par chaque bloc.

Pour commencer, l'architecture de l'encodeur se distingue par l'utilisation de l'apprentissage par transfert, c'est-à-dire que nous utilisons un modèle CNN préexistant dont les poids des kernels de convolution ont déjà été entraînés sur la base de données ImageNet. Pour des raisons de compréhension des modèles préentraînés, il a été décidé de choisir le modèle VGG-16 (Simonyan et Zisserman 2015), qui est facile à mettre en place en raison de sa faible profondeur. Les poids initiaux de l'encodeur sont

ceux de VGG-16 ; cependant, ils ne sont pas gelés pour permettre à l'encodeur de se spécialiser davantage dans la segmentation du réseau de desserte.

L'encodeur à une profondeur de 5 blocs convolutifs tandis que le décodeur admet une suite de 4 blocs. Les blocs convolutifs se composent de deux étapes de convolutions ayant chacune *ReLU* comme fonction d'activation. Les blocs de niveau 1 exécutent 64 convolutions, pour chaque niveau de profondeur supplémentaire le nombre de convolutions double pour atteindre 1024 convolutions au plus loin de l'encodeur. Chaque bloc convolutif admet aussi une étape de *dropout*. Cette étape force le modèle à oublier 20% des informations apprises par chaque bloc convolutif. L'ajout de *dropout* a tendance à dégrader la précision du modèle, mais à augmenter la capacité de généralisation. Enfin, l'image de sortie est générée par un nombre de convolutions égales au nombre de classes d'entité à segmenter et utilise *softmax* comme fonction d'activation.

Le modèle U-net 3+ traite des images carrées de 224*224 pixels. De ce fait, chaque LRM est taillé pour que les bords de l'image soient dans des longueurs divisibles par 224. L'image taillée est découpée en de multiples images de 224*224 qui sont par la suite réassemblés pour revenir à une image segmentée dont les dimensions sont semblables à l'image taillée. Le modèle est entraîné sur la base de 205 images provenant de 4 parcelles différentes, les masques de vérité sont créés depuis une digitalisation manuelle. Afin de renforcer l'apprentissage du modèle, les données d'entraînement sont augmentées artificiellement en utilisant *tensorflowdataset* (Kalinowski, Falbel, Allaire, Tang, et al. 2024), chaque image est dupliquée en ajoutant des modifications. Cette augmentation du nombre de données permet d'atteindre 1025 images où chaque image est associée à un masque de vérité. L'augmentation comprend 4 types de transformation, la première rotâtes les images d'un quart sur la droite, la deuxième inverse l'image sur un axe horizontal, la troisième inverse l'image sur un axe vertical et la quatrième inverse l'image sur un axe horizontal puis vertical. Pour chaque type de modification, le contraste et la luminosité des images sont modifiés aléatoirement dans des plages de valeurs altérant peu la compréhension de l'image. Cette étape permet de diversifier les données d'entraînement et donc d'introduire plus de variabilité pour permettre une meilleure généralisation du modèle U-net 3+. Dans notre cas, 80% des données sont allouées à l'entraînement du modèle (820 images) et 20% utilisé pour la validation du modèle (205 images), cette division du jeu de données est réalisée par une sélection aléatoire des images.

L'entraînement du modèle a été réalisé sur 50 époques en utilisant une taille de lot de données de 3. À chaque itération, le modèle compare les résultats avec les masques de vérité en utilisant une fonction de perte et cherche à minimiser le résultat à chaque lot de données. Ici on utilise une fonction de perte

d'entropie-croisée catégorielle. Un lot représente le nombre d'images traitées par le modèle avant chaque ajustement des poids, ici la taille des lots utilisés est de 3. Ainsi, chaque itération compte 273 ajustements en utilisant l'optimiseur *Adam*. Cet optimiseur a été choisi étant donnée sa grande popularité dans la littérature. L'ajustement des poids du modèle consiste à minimiser le résultat de la fonction de perte. Ce nombre élevé d'itérations a été permis par l'entraînement du modèle avec un processeur graphique (GPU) NVIDIA RTX A4000. Malgré la puissance du processeur graphique utilisé, le nombre de données traitées par lot a dû être limité pour des raisons de gestion de la mémoire du GPU.

4.3 Analyse de la qualité de la segmentation de la desserte forestière par U-Net 3+

La qualité générale de l'apprentissage est testée par l'intermédiaire de 3 métriques qui permettent de rendre compte des performances finales du modèle de segmentation. Malheureusement, du fait d'un choix de l'encodage des données en *one-hot* la précision de la segmentation pour chaque classe n'a pas été mesurée. Ici, il a été choisi de tester la qualité de la segmentation en calculant la précision globale, un coefficient de Dice (Score F1) moyen et un IoU (Intersection over Union ou Indice de Jaccard) moyen. Au terme de l'apprentissage, le modèle atteint une précision de 0.975, un coefficient

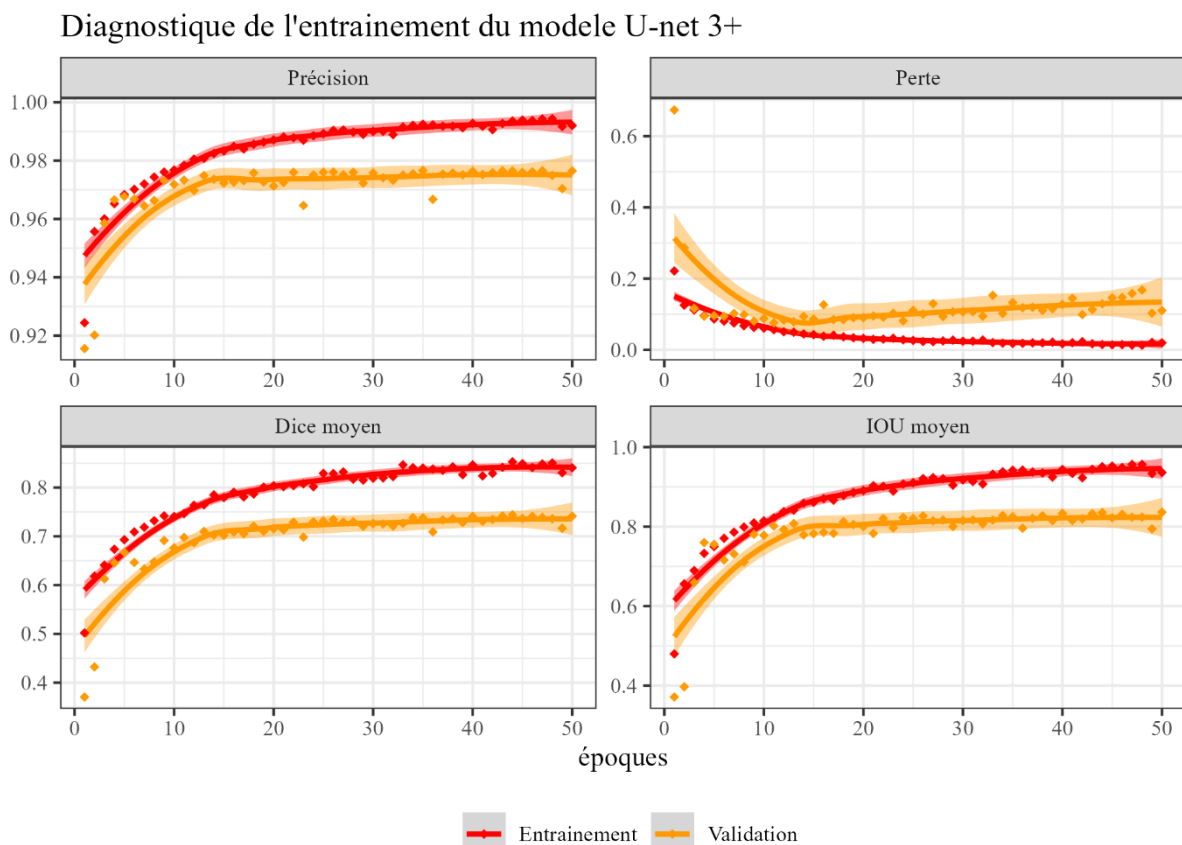


Figure 8) Résumé de l'évolution des métriques et de la perte du modèle au cours de l'entrainement.

de Dice moyen de 0.74 et un IoU moyen (Intersection Over Union) de 0.81 pour les données de validation (fig. 8). Les résultats n'ont pas pu bénéficier d'une vérification terrain.

Une comparaison visuelle des résultats du modèle montre qu'il parvient à proposer un réseau de desserte plus précis que ce que peuvent proposer les exploitants. Bien sûr, il parvient à détecter des pistes non renseignées par les exploitants (fig. 9). Cependant, la qualité de la segmentation est tributaire de la qualité du LRM SAILORE. Là où la visualisation des pistes est mauvaise, la segmentation sera forcément dégradée.

Comparaison entre les pistes déclarées par l'exploitant et les pistes détectées par la segmentation

Parcelle : MAN 445




Figure 9) Comparaison entre les pistes déclarées par l'exploitant et les pistes détectées par la segmentation. Zoom sur une partie des pistes principales et secondaires de la parcelle MAN 445.

5 Création de variables pour l'étude des impacts de l'EFI et analyses statistiques exploratoires

5.1 Mise en valeur des impacts de l'exploitation forestière par la création de variables

Du fait du cheminement méthodologique que nous suivons, nous disposons à présent d'un large éventail de modèles numériques et de données pour caractériser la structure forestière. Le sous-bois est modélisé par le RDM, la canopée par les CHM, et le réseau de desserte par la sortie de l'U-Net 3+. À partir de ces données, il devient possible de calculer divers indicateurs pour rendre compte des impacts de l'EFI. Depuis les CHM et le RDM, nous pouvons mesurer des différences, traduisant l'évolution de l'encombrement du sous-bois et de la hauteur de la canopée. Pour calculer le delta de la canopée, seuls les pixels supérieurs à 10 m sont conservés. De cette manière, les zones déboisées ne sont pas comptabilisées dans l'évolution de la hauteur de la canopée. Les CHM permettent aussi de modéliser les trouées pour chaque CHM, et donc de déduire le gain de trouées entre un CHM pré-exploitation et un CHM post-exploitation. Les trouées sont modélisées en utilisant le package R ForestGapR (Silva et al. 2019), en suivant la définition de trouées de Hunter (Hunter et al. 2015). Ainsi, toute ouverture de la canopée de plus de 10 m de profondeur et d'une surface minimale de 10 m², soit 10 pixels contigus, est considérée comme une trouée. Depuis les CHM pré-exploitation nous avons décidé d'extraire l'écart-type de la canopée, cela permet d'approcher le degré initial d'anisotropie de la hauteur de la canopée. Cela permet de rendre compte si la forêt semble initialement perturbée.

Le modèle U-net 3+ permet de cartographier le réseau de desserte. Cette cartographie est utilisée pour créer une carte de la distance des pixels au réseau de desserte et d'approcher la densité du réseau de desserte. Le relief étant aussi un facteur influant sur l'ouverture de la canopée, la pente est extraite des MNT. Pour compléter notre jeu de variables, nous intégrons des données indiquant la position des arbres abattus ainsi que le nom de l'exploitant et la modalité d'EFI associée à l'exploitation. La modalité du type d'EFI se réfère à la version de la charte EFI qui encadre l'exploitation forestière.

Pour chaque parcelle, nous réalisons un pavage hexagonal, où chaque hexagone mesure 50 m de large pour 57 m de long. Le pavage est entièrement inclus dans la forme de la parcelle. Du fait de toutes les données extraites, pour chaque hexagone, nous possédons un ensemble de variables (fig. 10). Les variables extraites peuvent être regroupées selon trois groupes :

- 1) Les variables relatives à l'évolution de la structure forestière permettent de traduire les impacts de l'exploitation forestière sur la structure de la forêt. Ici nous avons :
 - La moyenne de l'évolution de la canopée supérieure à 10 m
 - La moyenne de l'évolution de l'encombrement du sous-bois entre le sol et 6 m
 - La proportion de la surface du gain de trouées
- 2) Les variables relatives aux conditions initiales de la forêt servent de témoins de la participation de la structure initiale de la forêt sur sa dégradation après exploitation. Nous avons :
 - L'écart-type de la hauteur de canopée préexploitation
 - La pente moyenne
- 3) Les variables relatives à l'exploitation forestière sont particulièrement intéressantes, car elles permettent de définir l'intensité de l'exploitation forestière. Nous possédons :
 - La distance moyenne au réseau de desserte
 - La proportion de la surface recouverte par le réseau de desserte
 - Le nom de la compagnie et la modalité d'EFI associé à l'exploitation
 - Le nombre d'arbres abattus

Ensemble des variables générées depuis le traitement des données LIDAR
Parcelle : SAO 504

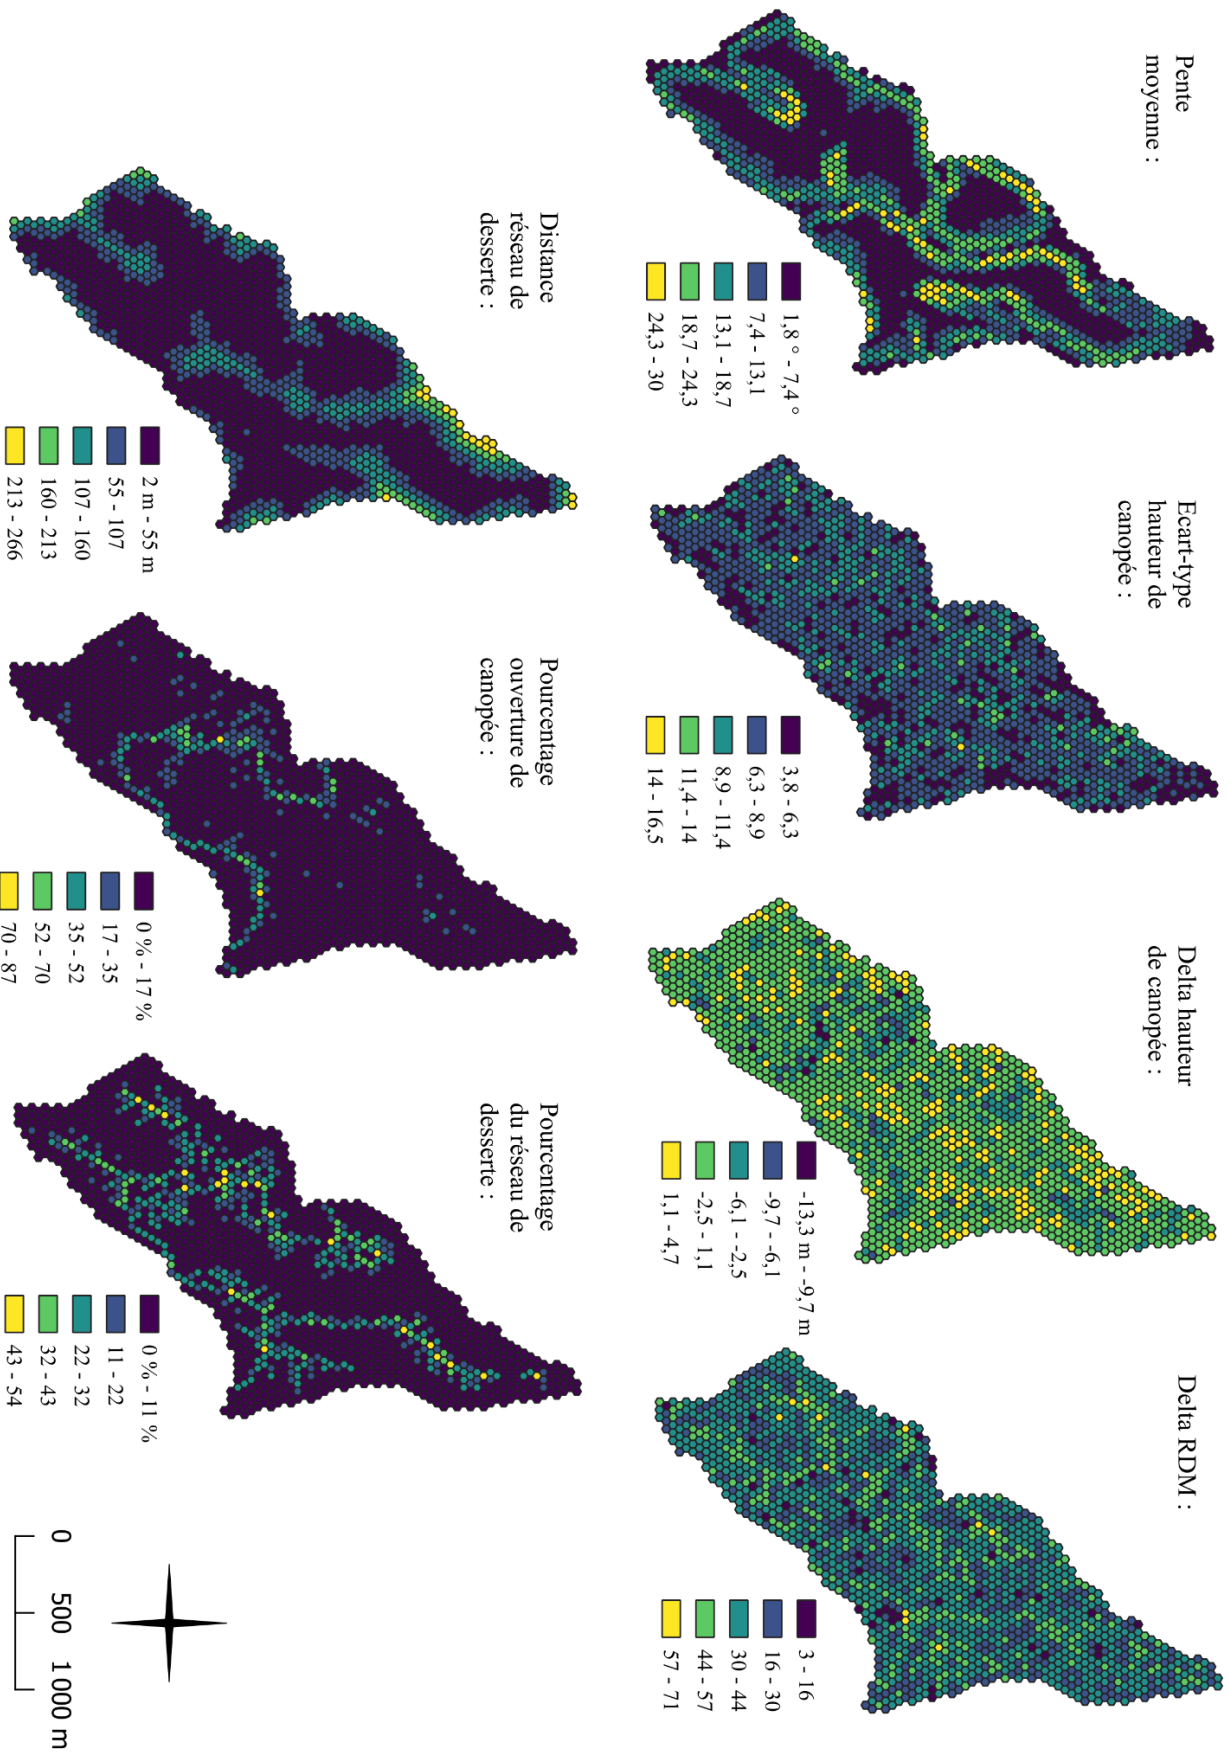


Figure 10) Carte des variables issues du traitement des données LiDAR et extraites par un pavage hexagonal

5.2 Démarche statistique pour l'exploration des impacts de l'EFI

L'analyse statistique commence par des analyses bivariées descriptives avant de réaliser une analyse multivariée exploratoire. Depuis le panel des variables relevées dans l'étape précédente, il devient possible d'initier une analyse statistique exploratoire afin de comprendre l'articulation des variables pouvant expliquer les impacts d'une EFI. Puisque nous nous intéressons uniquement à l'exploitation forestière, les hexagones intersectant à moins de 50% un UP ont été retirés de l'analyse. Il en va de même pour les hexagones intersectant un tampon de 12,5 m autour des routes ONF et ceux intersectant les places de dépôts. Par ailleurs, la variable liée au nombre d'arbres abattus limite les parcelles pouvant être utilisées pour les analyses statistiques. Ainsi, seules les 6 parcelles où la donnée des arbres abattus est correcte pourront être intégrées dans les analyses statistiques. Pour mener à bien l'analyse exploratoire des données, nous réalisons une Analyse en Composantes Principales (ACP) sur les variables quantitatives. Cette étape nous a permis de condenser l'information en identifiant les relations entre les variables en mettant en évidence les structures de similarité parmi les individus. En comprenant ces relations, nous pouvons dégager des patterns généraux et identifier des regroupements significatifs.

Par la suite, il a été choisi de proposer des modèles de régression linéaire multiple pour examiner l'influence de plusieurs variables explicatives sur les variables qui semblent être les plus pertinentes à traiter au vu de la spatialisation des individus sur l'ACP. Afin d'optimiser ces modèles, nous avons appliqué une méthode de sélection des variables automatique, permettant d'identifier les variables ayant le meilleur pouvoir explicatif en se basant sur le critère d'information d'Akaike (AIC). Ce processus a conduit à la simplification des modèles en conservant uniquement les variables les plus pertinentes.

Une fois les modèles potentiels créés et analysés, nous avons évalué les effets de la variable catégorielle 'Exploitant et modalité d'EFI' en calculant les moyennes marginales estimées des variables (en anglais : *estimated marginal means* ; EMM) via le package *emmeans* (Lenth et al. 2024). Cela permet de fournir des moyennes ajustées à chaque variable. Les comparaisons par paires des moyennes marginales ont été réalisées en utilisant un ajustement de Bonferroni. Ce genre d'ajustement est essentiel dans les comparaisons par paires pour contrôler le taux d'erreur global et éviter les conclusions erronées dues à des découvertes fortuites. Il rend les tests plus rigoureux en ajustant le seuil de significativité pour chaque comparaison.

6 Analyses statistiques pour la quantification des impacts de l'EFI

6.1 Analyse bivariée

La première analyse statistique consiste à explorer les relations bivariées entre toutes les variables qui nous servent à décrire l'exploitation forestière et ses impacts. La figure 11 décrit efficacement l'étendue des relations bivariées de notre jeu de données. Ici, nous nous concentrerons uniquement sur les relations très significatives (inférieure à un risque d'erreur α de 1%) et ne traiterons que des relations modérément corrélées ($0.3 < r < 0.5$) et très corrélées ($0.5 < r < 1$). Il en va de même pour les anti-corrélations).

Parmi les variables relatives à l'état initial de la forêt, la variable traduisant l'anisotropie initiale de la hauteur de la canopée admet des relations significatives uniquement avec le delta de canopée et du RDM, mais propose des coefficients de corrélation faible (respectivement $r = -0.066$ et $r = -0.205$). De son côté, la pente admet des coefficients de corrélation modérément fort avec les variables relatives au réseau de desserte. L'exploitation étant proscrite dans les pentes supérieures à 22%, cela permet d'expliquer la présence d'une corrélation.

Les variables associées avec les impacts de l'exploitation forestière admettent des relations statistiques intéressantes. Le delta de la hauteur de la canopée est modérément corrélé avec la distance au réseau de desserte ($r = 0.312$) ce qui laisse supposer que plus une région est éloignée du réseau de desserte moins elle est susceptible de subir une baisse de la hauteur de canopée après une exploitation forestière. Le delta de la hauteur de la canopée est anti-corrélé avec le pourcentage de trouée et le nombre d'arbres abattus, respectivement $r = -0.654$ et $r = -0.676$. Cela laisse supposer que plus une région admet de grandes trouées ou une coupe intensive, plus cette région est sensible à une baisse de la hauteur de la canopée. Quant à lui, le delta du RDM semble modérément corrélé avec la distance à la desserte, le pourcentage de trouées et le nombre d'arbres coupés (respectivement $r = -0.441$, $r = 0.392$ et $r = 0.372$). Cela suggère que lorsque l'intensité de coupe ou l'ouverture de la canopée augmentent l'encombrement du sous-bois a tendance à se dégrader modérément. Par ailleurs, la dégradation du sous-bois admet une corrélation satisfaisante avec le pourcentage de surface de route ($r = 0.503$). Ainsi, quand le pourcentage de surface de desserte augmente, fatalement l'encombrement du sous-bois se dégrade. Enfin, le pourcentage de trouées est modérément corrélé avec le pourcentage de desserte ($r = 0.444$) et plus fortement avec le nombre d'arbres coupés ($r = 0.531$). Cela laisse présupposer que les

zones de grandes trouées ont tendance à se situer dans les régions où le réseau de desserte est important ou là où l'exploitation forestière est particulièrement importante.

Matrice de corrélation des variables analysées

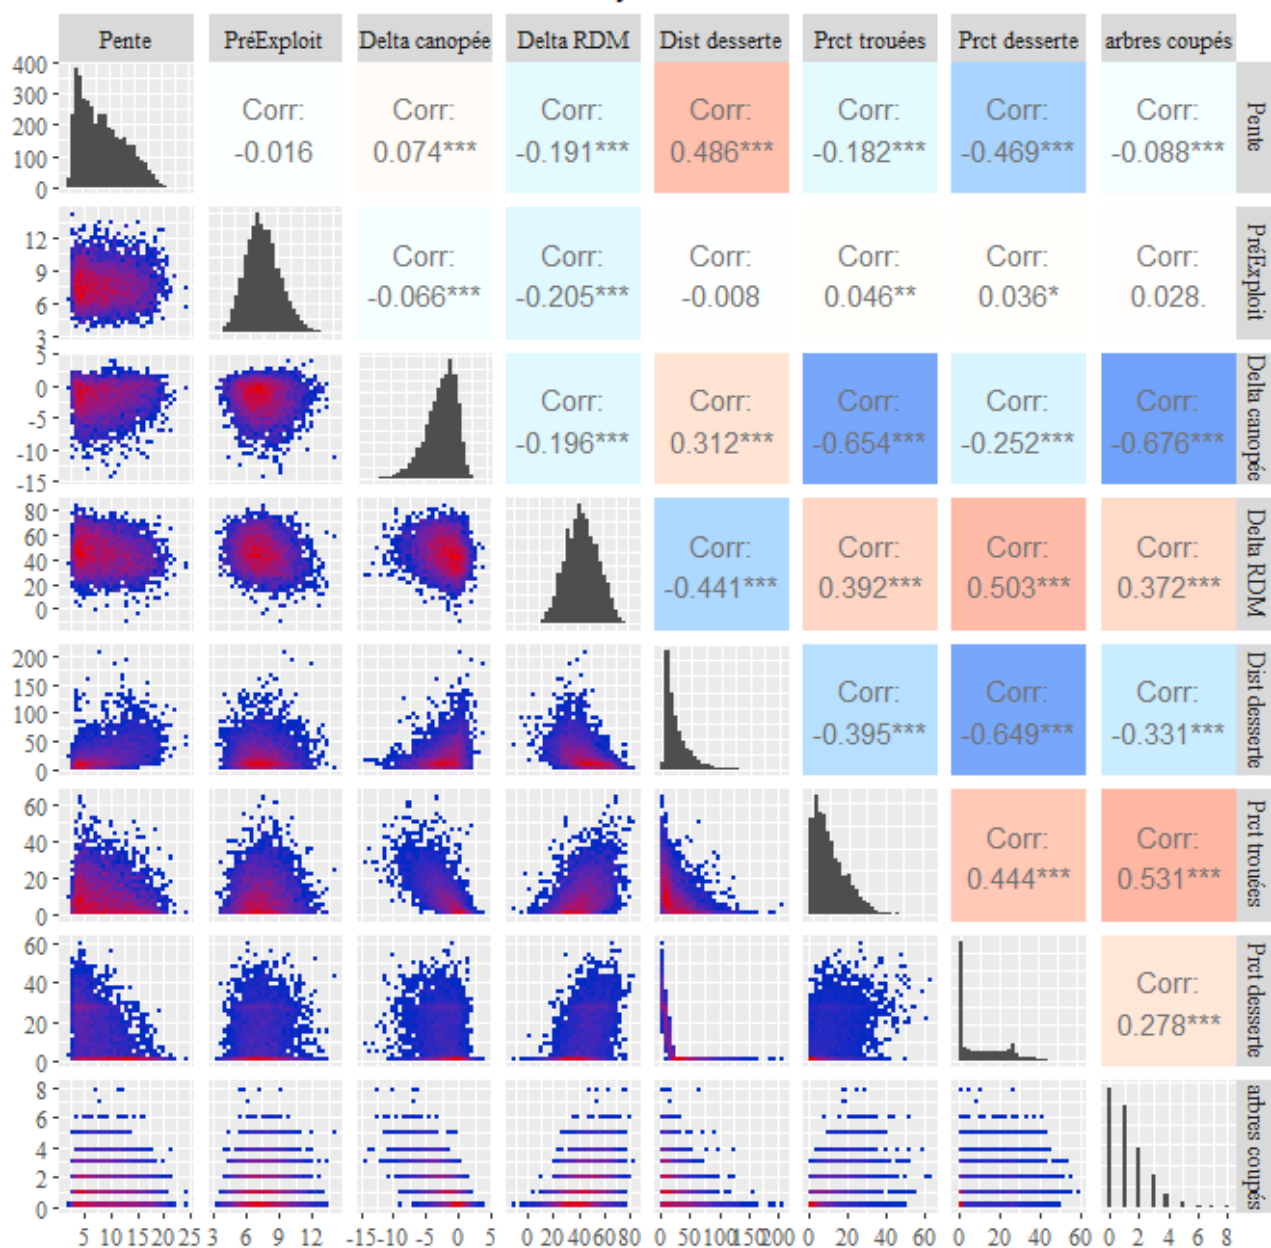


Figure 11) Matrice des corrélations entre les variables étudiées. Le coefficient de corrélation est calculé selon la méthode de Pearson. Le nombre d'étoiles se réfère au seuil de risque d'erreur α (* 10% ; ** 5%, *** 1%). La moitié inférieure de la matrice représente la densité d'individus. Le rouge signifie une forte densité et l'inverse pour le bleu. La variable « PréExploit » représente l'anisotropie initiale de la hauteur de la canopée.

Jusque-là, cette observation bivariée des relations entre nos variables montre qu'il existe des liens certains entre certaines variables traduisant les impacts à la structure forestiers et les variables relatives à l'intensité de l'exploitation forestière. Par exemple, le delta de la hauteur de canopée peut être

expliqué par le nombre d'arbres abattus. La dégradation du sous-bois semble être expliquée par le pourcentage de surface alloué au réseau de desserte. L'ouverture de la canopée est principalement expliquée par le nombre d'arbres coupés. De leur côté, les conditions initiales de la forêt ne semblent pas influencer sur la dégradation de la structure forestière post exploitation.

6.2 Analyse exploratoire des relations multivariées

Bien que l'analyse bivariée soit très instructive sur les relations entre une variable par rapport à une autre, cela ne permet d'approcher que trop simplement l'articulation des relations intervariables. La présente ACP (fig. 12) permet de mieux explorer les relations entre les variables en décelant des groupes de corrélation. À la vue du pouvoir explicatif des deux premières dimensions, à savoir : 41.4% pour la dimension 1 et 18 % pour la dimension 2, il a été choisi de traiter nos variables uniquement sur ces deux dimensions. L'ajout d'une troisième permet d'expliquer 13.9 % de variance supplémentaire, mais complexifie grandement l'interprétation. La première dimension est principalement constituée du pourcentage de l'ouverture de la canopée, du pourcentage de la surface de la desserte et de la distance de la desserte. Ces variables contribuent respectivement à 17.92%, 17.12% et 17.26%. La dimension 2 est constituée en très grande partie du delta de hauteur de la canopée et de la pente, qui contribue respectivement à 24.54% et 24.25%.

Cartographie des variables et des individus dans l'ACP

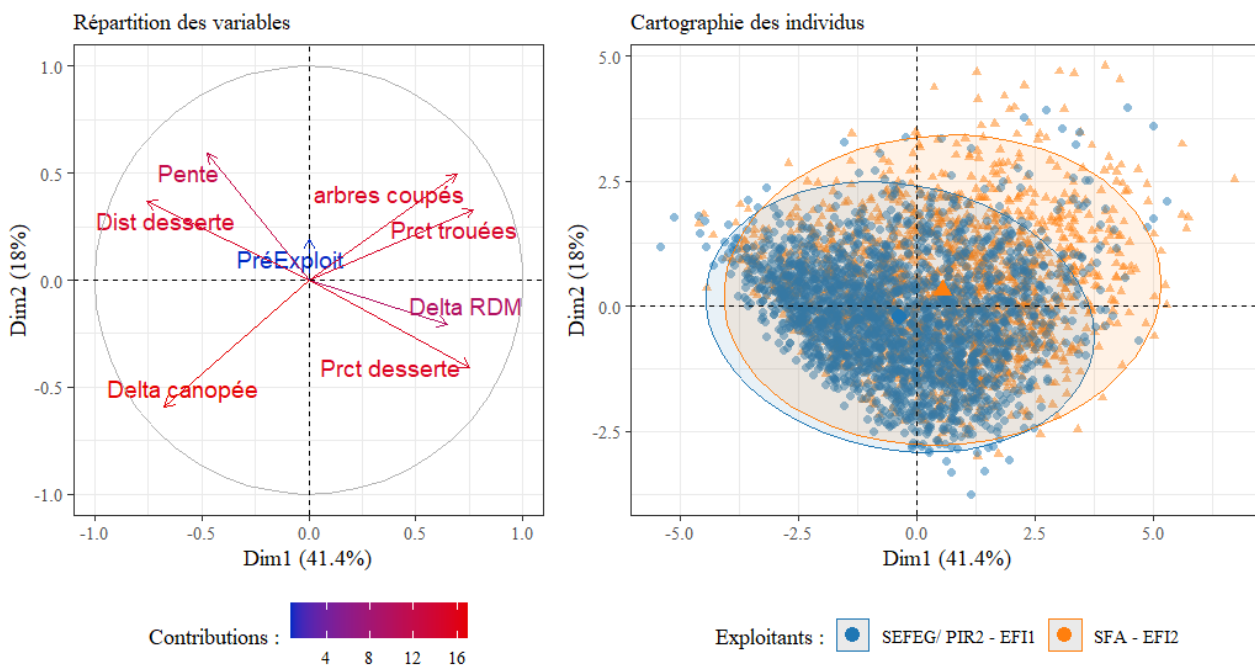


Figure 12) Représentation graphique de la spatialisation des variables et des individus sur les deux premières dimensions de l'ACP.

Deux groupes de corrélation ressortent nettement dans notre analyse. Le premier inclut le nombre d'arbres coupés, le pourcentage de trouées et le delta de la hauteur de canopée. On observe que plus le nombre d'arbres coupés augmente, plus la surface des trouées s'élargit, entraînant une baisse de la hauteur de la canopée, sans pour autant impacter l'encombrement du sous-bois. Le second groupe se compose de la distance à la desserte et du pourcentage de surface du réseau de desserte, auxquels s'ajoutent, dans une moindre mesure, la pente et le delta du RDM. Ce groupe montre que l'augmentation de la densité du réseau de desserte tend à désencombrer le sous-bois. L'anisotropie initiale de la canopée, en revanche, n'apparaît pas comme un facteur explicatif significatif. Il ne semble pas avoir de relation entre les groupes de variables traduisant les conséquences du nombre d'arbres coupés et le groupe qui traduit les conséquences liées au réseau de desserte.

6.3 Impacts de l'exploitation à la canopée selon l'exploitant et la modalité d'EFI

La cartographie des individus sur la figure 12, selon le type d'exploitant et la modalité de l'EFI, met en évidence des différences de comportement. Bien que les ellipses représentant les différents exploitants se chevauchent, suggérant des comportements relativement similaires, une observation plus attentive révèle que l'ellipse de SFA est plus étendue que celle de SEFEG/PIR2. Cette expansion se dirige vers les zones de l'ACP associées au nombre d'arbres coupés et au pourcentage de surface des trouées. Ainsi, bien que les deux types d'exploitants présentent des approches globalement comparables, SFA semble adopter une gestion moins restrictive, cherchant à maximiser le nombre d'arbres coupés provoquant *in extenso* une augmentation de la surface des trouées et la réduction de la hauteur de la canopée. Le groupe de variables associé à la desserte forestière ne semble pas permettre d'identifier de différence entre les exploitants.

Du fait de la spatialisation des individus sur l'ACP, il est intéressant de tester l'effet exploitant sur le pourcentage de l'ouverture de la canopée et la variation de hauteur de la canopée. L'analyse des EMM pour quantifier l'effet des exploitants sur le pourcentage d'ouverture de la canopée montre que SEFEG/PIR2 provoque moins d'ouverture de canopée que SFA avec une différence de 1.87 % entre les deux exploitants (fig. 13). SFA propose une EMM à 12% alors que SEFEG/PIR2 se restreint à une EMM de 10.2%. Cette différence est hautement significative, elle admet une *p-value* inférieur à 0.0001.

Modélisation de la moyenne de l'ouverture de la canopée en fonction de l'exploitant

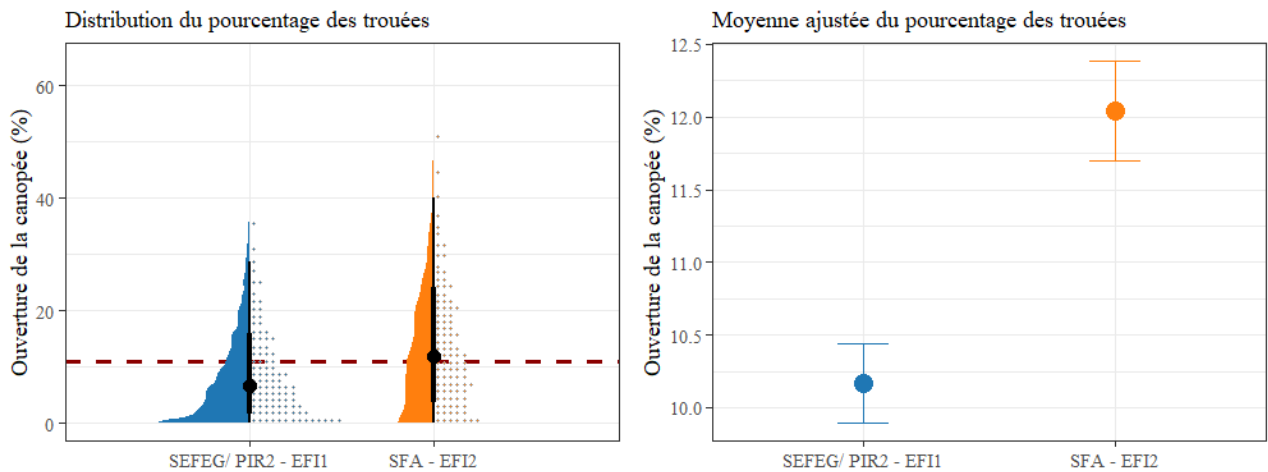


Figure 13) Modélisation de la moyenne ajustée pour le pourcentage d'ouverture de la canopée en fonction de l'exploitant. Le graphique de gauche rend compte des moyennes observées, la ligne rouge représente la moyenne observée globale.

Par rapport à l'impact sur la hauteur de la canopée, les résultats montrent une légère différence liée à l'effet exploitant. La différence dans la variation de hauteur de la canopée est de seulement 0.1 m entre les deux exploitants SFA semble encore une fois manifester plus d'impacts que SEFEG/PIR2 (Fig. 14). Toutefois, avec une *p-value* de 0.11 il n'est pas possible que cette différence soit statistiquement significative.

Modélisation de la moyenne du delta de la hauteur de la canopée

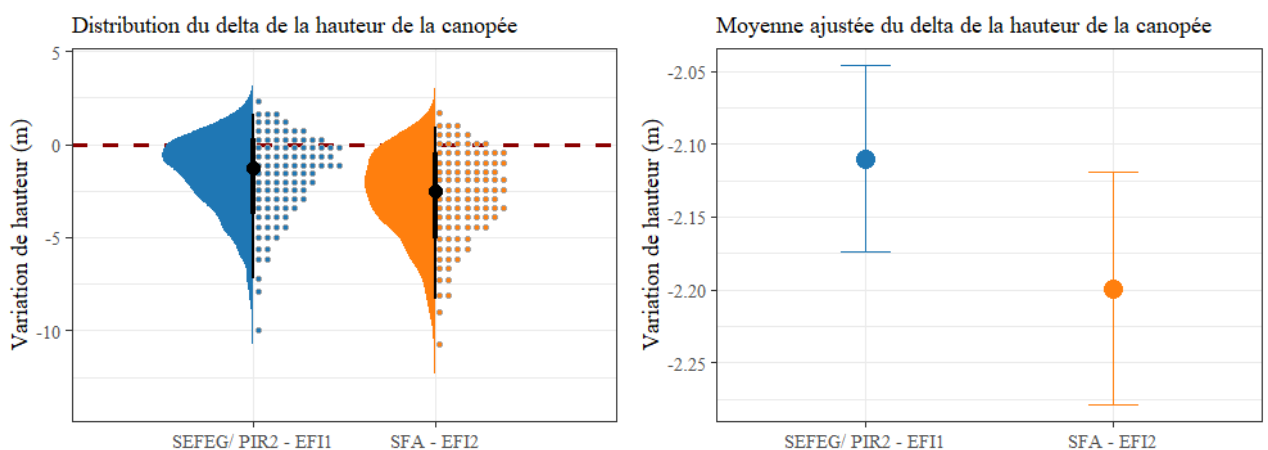


Figure 14) Modélisation de la moyenne ajustée pour la variation de la hauteur de la canopée en fonction de l'exploitant. Le graphique de gauche rend compte des moyennes observées, la ligne rouge représente la moyenne observée globale.

Au terme de cette analyse pour chercher à quantifier les impacts liés à l'exploitant ou au type d'EFI. On observe que l'effet exploitant joue un rôle certain sur les impacts de l'exploitation. Il conditionne très significativement le pourcentage d'ouverture de la canopée, mais pas la variation de la hauteur de la canopée. Ainsi, bien que l'EFI impose une charte de l'exploitation forestière. Les impacts à la canopée sont différents selon les exploitants et la modalité de la charte en cours.

7 Discussion et perspectives

Au regard de la qualité des données LiDAR, la méthode utilisée semble tout à fait efficace pour mesurer les impacts de l'EFI sur la forêt guyanaise. Toutefois, puisque notre méthode traite quasi uniquement de données issues du LiDAR, elle est fatalement sensible à la qualité de ces données.

Tout d'abord, nous avons pu construire des CHM de bonne qualité par la méthode Highest, car la densité de pulses de nos données LiDAR est suffisante pour produire des CHM de qualité avec une RMSE inférieure à 4 mètres. En outre, s'il est nécessaire de manipuler des données LiDAR d'une qualité moins bonne, alors il est préférable de se tourner vers des méthodes de construction de CHM plus sophistiqué comme T Spikefree ou L Spikefree.

Concernant la desserte forestière, il est important de noter que le modèle de segmentation du réseau de desserte exploite des données dont la qualité est très hétérogène. En effet, les LRM sont produits depuis les MNT dont la qualité dépend des paramètres d'acquisition des données LiDAR. Ainsi, la qualité de la segmentation dépend intrinsèquement de la qualité des données LiDAR, notamment de la densité de pulses (Annexe 3). Forcément, un nuage de faible densité de pulses signifie un LRM dont les détails peuvent ne pas être assez fins pour capter toutes les subtilités des formes des routes et des pistes. Cela est d'autant plus vrai si l'on considère l'importance du couvert forestier des parcelles étudiées. Les extrémités des pistes sont aussi difficiles à segmenter du fait d'un faible impact au sol et à la canopée. L'effet de la densité de pulses pour la bonne segmentation du réseau de pistes n'a pu être identifié que par une comparaison visuelle des résultats. À une densité de 5 p/m² la segmentation du réseau de desserte est plutôt mauvaise. À 10 p/m² elle devient assez complète, mais la différenciation entre les différents types de voies reste assez pauvre. Dès 30 p/m² la qualité de la segmentation et de la différenciation des types de desserte devient très acceptable.

Le déroulé méthodologique propose de cartographier la desserte forestière par une méthode semi-automatique. Cela permet de s'émanciper des données préexistantes de la desserte dont la qualité est trop aléatoire entre les différentes parcelles. La méthode de segmentation de la desserte propose

globalement de bons résultats. Cependant, pour atteindre de tels résultats, il a été choisi de ne pas stopper l'entraînement du modèle en dépit d'une faible augmentation de la valeur de perte dès la 15^e époque. Dans la plupart des cas, une augmentation de la valeur de perte est synonyme d'un surapprentissage du modèle, il est donc souhaitable de ne pas tolérer une augmentation de la valeur de perte. Néanmoins, les résultats de la segmentation après 15 époques étant trop bruités, nous avons pris le parti de tolérer l'augmentation de la valeur de perte. Cela a pour conséquence de créer un modèle très spécifique aux données d'apprentissage, mais produisant des données très peu bruitées. Par ailleurs, le modèle U-Net 3+ semble avoir du mal à traiter le bord de chaque image, ce qui pose un léger problème pour la cohérence de l'image finale. Pour régler ce problème, il est préférable de transmettre plus de contexte spatial aux images traitées. Pour cela, on peut provoquer un chevauchement entre les images traitées dans le découpage de l'image initiale. Aussi, le modèle utilise l'apprentissage par transfert, en utilisant VGG-16 comme encodeur. Cependant, les tables de performance ont tendance à admettre que les encodeurs utilisant des architectures basées sur des réseaux neuronaux résiduels proposent de meilleure segmentation (Zhang et al. 2020). Ainsi, il peut être judicieux d'utiliser des encodeurs préentraînés comme resnet-101 ou resnet-152. Ces deux derniers points sont particulièrement importants pour améliorer les performances du modèle.

La cartographie du réseau de desserte et la génération des divers modèles numériques permettent d'extraire de nombreuses variables. S'il est décent de considérer que le réseau de piste et la canopée nous permettent de tirer de bonnes conclusions sur les impacts de l'exploitation forestière, la variable permettant de rendre compte du sous-bois est plus discutable. En effet, le delta RDM traduit très difficilement les impacts de l'exploitation sur le sous-bois. Néanmoins, au vu de la difficulté de produire une variable qui décrit efficacement la dégradation du sous-bois, il a été choisi de conserver le delta RDM pour tout de même considérer les impacts au sous-bois. Les variables relatives au réseau de desserte admettent aussi quelques limites. Bien qu'elles soient essentielles à notre étude, il est probable qu'inclure une différence entre les différents types de voies permettent d'augmenter la qualité de notre jeu de données. Cependant, cela demande de proposer un modèle de segmentation du réseau de desserte encore plus performant que celui proposé dans cette étude.

Concernant les données exploitées, la donnée relative au nombre d'arbres abattus est assez limitante du fait de sa qualité. Cette donnée est fournie par l'exploitant et est créée en enregistrant la position de chaque arbre abattu avec un GPS d'une précision de plus ou moins 12 m de rayon. Par ailleurs, l'étude devait initialement considérer plus de parcelles, mais le nombre de données manquantes des autres parcelles étant trop important, nous nous sommes limités à 6 parcelles. L'étude devait aussi inclure une variable pour la surface terrière des arbres abattus. Mais le nombre de données manquantes pour

le diamètre des arbres étant trop important, il a été choisi de retirer cette variable de l'analyse. Aussi, nous avons volontairement confondu l'information exploitant et la modalité de l'EFI, cela par souci de transparence dans l'analyse. Cependant, les deux modalités d'EFI identifiées comme étant très similaires, il est peu probable qu'elles puissent expliquer les résultats. Ainsi, il est possible d'améliorer l'amplitude de l'analyse des données en rajoutant davantage de parcelle étudiée et de variables, à condition que la qualité des données terrain le permette.

Enfin, le cheminement statistique qui assure l'analyse des données pour la mise en valeur des impacts de l'exploitation forestière n'est pas exempt de critique. Bien que la marche suivie soit pertinente pour mener une analyse exploratoire, elle souffre de la non-considération des relations non linéaire entre les variables. En effet, il aurait été souhaitable de considérer la non-linéarité des relations pour proposer une analyse plus rigoureuse. Il a été choisi de se limiter à une analyse moins sophistiquée pour des raisons de temps.

Conclusion

Au cours de ce mémoire, nous sommes parvenus à constituer une chaîne de traitement qui permet d'extraire des variables pour analyser les impacts de l'EFI sur la structure de la forêt guyanaise. La mise en place d'une méthodologie manipulant quasi uniquement des nuages de points issue de LiDAR aéroportés vient appuyer l'importance du LiDAR pour la cartographie de la forêt en milieu équatorial. Nous avons montré l'importance de l'optimisation des méthodes pour la génération des CHM et nous sommes parvenus à mettre au point une méthode performante pour la cartographie de la desserte forestière. Une telle optimisation du traitement des données LiDAR pour la génération de données a permis de mettre en lumière les impacts de l'EFI par une analyse statistique exploratoire assez succincte.

Pour la génération des CHM, un certain effort a été mis en œuvre pour s'assurer de choisir la méthode optimale. Ici, la méthode Highest a été choisie, car elle semble efficace lorsque la densité de pulses des données excède les 5 p/m². Du fait de l'analyse comparative des différentes méthodes de CHM, nous pouvons nous assurer de la fiabilité des données. Pour assurer des comparaisons pertinentes entre les CHM, une méthode de dégradation des nuages de points par pulses a été mise en place afin d'étalonner au mieux la densité de pulses des données post-exploitation sur la densité de pulses des données de préexploitation.

La mise au point d'un modèle de segmentation multiclasse a permis d'explorer l'effet de la desserte forestière sur la structure de la forêt en s'émancipant de l'utilisation de données extérieures. Bien que tributaire de la qualité des données LiDAR, le modèle de segmentation des pistes par U-Net 3+ admet des capacités de segmentation très satisfaisante avec un coefficient de Dice moyen de 0.74 et un score IoU moyen de 0.81. Pour les parcelles supérieures à 10 p/m², cela permet de générer un réseau de desserte dont la qualité est acceptable pour cette étude.

Les analyses statistiques réalisées ont permis de démontrer que les pratiques d'EFI influencent significativement certains aspects de la structure forestière, notamment la hauteur de la canopée et son ouverture. Le nombre d'arbres coupés a un effet direct sur la variation de la hauteur de la canopée ($r = -0.676$) et sur l'augmentation de l'ouverture de la canopée ($r = 0.531$). Tandis que le pourcentage de l'emprise de la desserte contribue à l'augmentation du désencombrement du sous-bois ($r = 0.503$) et, dans une moindre mesure, à l'ouverture de la canopée ($r = 0.444$). Il apparaît également que l'état initial de la forêt avant exploitation n'influence pas significativement les impacts observés après l'exploitation, indiquant que la dégradation de la structure forestière dépend principalement des interventions humaines, plutôt que de la configuration naturelle des forêts ou de la topographie. L'analyse en composantes principales confirme cette séparation nette entre les variables associées à l'exploitation et celles associées aux impacts.

Cependant, l'analyse par exploitant révèle une variabilité importante dans les effets observés, en particulier pour l'ouverture de la canopée, où des différences significatives entre exploitants ont été identifiées. Cette hétérogénéité indique que les impacts de l'EFI ne peuvent pas être appréhendés de manière uniforme : chaque exploitant génère des effets spécifiques sur la structure forestière. Il devient donc difficile de généraliser les impacts de l'EFI sans tenir compte des variations liées aux pratiques individuelles des exploitants. En définitive, cette étude montre que, même dans un cadre d'exploitation à faibles impacts, les conséquences sur la structure forestière peuvent varier fortement selon les exploitants. Ces résultats soulignent la nécessité de mettre en place des approches différenciées et adaptées pour évaluer et gérer durablement les forêts exploitées en Guyane française.

Bibliographie

- Abdi, Omid, Jori Uusitalo, et Veli-Pekka Kivinen. 2022. « Logging Trail Segmentation via a Novel U-Net Convolutional Neural Network and High-Density Laser Scanning Data ». *Remote Sensing* 14(2): 349. doi:10.3390/rs14020349.
- Affek, Andrzej Norbert, Maria Zachwatowicz, Agnieszka Sosnowska, Alina Gerlée, et Krzysztof Kiszka. 2017. « Impacts of modern mechanised skidding on the natural and cultural heritage of the Polish Carpathian Mountains ». *Forest Ecology and Management* 405: 391-403. doi:10.1016/j.foreco.2017.09.047.
- Allaire, J. J., Tomasz Kalinowski, Daniel Falbel, Dirk Eddelbuettel, Yuan Tang [aut, cph, Nick Golding, et al. 2024. « tensorflow: R Interface to “TensorFlow” ». <https://cran.r-project.org/web/packages/tensorflow/index.html> (27 août 2024).
- Arun, P. V. 2013. « A comparative analysis of different DEM interpolation methods ». *The Egyptian Journal of Remote Sensing and Space Science* 16(2): 133-39. doi:10.1016/j.ejrs.2013.09.001.
- Asner, Gregory P., Michael Keller, et Jose N. M. Silva. 2004. « Spatial and Temporal Dynamics of Forest Canopy Gaps Following Selective Logging in the Eastern Amazon ». *Global Change Biology* 10(5): 765-83. doi:10.1111/j.1529-8817.2003.00756.x.
- ASPR. 2019. « LAS Specification 1.4 - R14 ».
- Ballere, Marie. 2021. « Apport des données Sentinel-1 pour le suivi continu de la forêt tropicale : cas de la Guyane ». phdthesis. Université Gustave Eiffel. <https://tel.archives-ouvertes.fr/tel-03629552> (12 avril 2022).
- Bicknell, Jake E., Matthew J. Struebig, et Zoe G. Davies. 2015. « Reconciling Timber Extraction with Biodiversity Conservation in Tropical Forests Using Reduced-Impact Logging ». *Journal of Applied Ecology* 52(2): 379-88. doi:10.1111/1365-2664.12391.
- Bienz, Raffael, et Andréas Freuler. 2022. « A la recherche des layons perdus en forêt avec le LiDAR ». *La Forêt* (6): 20-24.
- Buján, Sandra, Juan Guerra-Hernández, Eduardo González-Ferreiro, et David Miranda. 2021. « Forest Road Detection Using LiDAR Data and Hybrid Classification ». *Remote Sensing* 13(3): 393. doi:10.3390/rs13030393.
- Chambers, Jeffrey Q., Gregory P. Asner, Douglas C. Morton, Liana O. Anderson, Sassan S. Saatchi, Fernando D. B. Espírito-Santo, Michael Palace, et Carlos Souza. 2007. « Regional Ecosystem Structure and Function: Ecological Insights from Remote Sensing of Tropical Forests ». *Trends in Ecology & Evolution* 22(8): 414-23. doi:10.1016/j.tree.2007.05.001.
- Coomes, Oliver T., Franque Grimard, Catherin Potvin, et Philip Sima. 2008. « The fate of the tropical forest: Carbon or cattle? » *Ecological Economics* 65(2): 207-12. doi:10.1016/j.ecolecon.2007.12.028.
- Coops, Nicholas C., Piotr Tompalski, Tristan R. H. Goodbody, Martin Queinnec, Joan E. Luther, Douglas K. Bolton, Joanne C. White, et al. 2021. « Modelling lidar-derived estimates of forest

attributes over space and time: A review of approaches and future trends ». *Remote Sensing of Environment* 260: 112477. doi:10.1016/j.rse.2021.112477.

Direction Territoriale de l'ONF Guyane. 2017. « Charte EFI 2017 ».

Duchelle, Amy E, Gabriela Simonet, William D Sunderlin, et Sven Wunder. 2018. « What is REDD+ achieving on the ground? » *Current Opinion in Environmental Sustainability* 32: 134-40. doi:10.1016/j.cosust.2018.07.001.

Dupuis, Chloé, Philippe Lejeune, Adrien Michez, et Adeline Fayolle. 2020. « How Can Remote Sensing Help Monitor Tropical Moist Forest Degradation?—A Systematic Review ». *Remote Sensing* 12(7): 1087. doi:10.3390/rs12071087.

Ellis, Peter W., Trisha Gopalakrishna, Rosa C. Goodman, Francis E. Putz, Anand Roopsind, Peter M. Umunay, Joey Zalman, et al. 2019. « Reduced-impact logging for climate change mitigation (RIL-C) can halve selective logging emissions from tropical forests ». *Forest Ecology and Management* 438: 255-66. doi:10.1016/j.foreco.2019.02.004.

FAO. 2014. *Evaluation des ressources forestières mondiales 2015*. Rome. Rapport national.

Ferraz, António, Sassan Saatchi, Clément Mallet, et Victoria Meyer. 2016. « Lidar detection of individual tree size in tropical forests ». *Remote Sensing of Environment* 183: 318-33. doi:10.1016/j.rse.2016.05.028.

Fischer, Fabian Jörg, Toby Jackson, Grégoire Vincent, et Tommaso Jucker. 2024. « Robust Characterization of Forest Structure from Airborne Laser Scanning – a Systematic Assessment and Sample Workflow for Ecologists ». : 2024.03.27.586702. doi:10.1101/2024.03.27.586702.

Fradette, Marie-Soleil, Antoine Leboeuf, Martin Riopel, et Jean Bégin. 2019. « Method to Reduce the Bias on Digital Terrain Model and Canopy Height Model from LiDAR Data ». *Remote Sensing* 11(7): 863. doi:10.3390/rs11070863.

Fuller, Douglas O. 2006. « Tropical Forest Monitoring and Remote Sensing: A New Era of Transparency in Forest Governance? » *Singapore Journal of Tropical Geography* 27(1): 15-29. doi:10.1111/j.1467-9493.2006.00237.x.

Gargominy, Terceirie, Régnier, Ramage, Dupont, Daskiewicz, et Poncet. 2022. *TAXREF, référentiel taxonomique pour la France : méthodologie, mise en œuvre et diffusion*.

Hesse, Ralf. 2010. « LiDAR-derived Local Relief Models – a new tool for archaeological prospection ». *Archaeological Prospection* 17(2): 67-72. doi:10.1002/arp.374.

Holmgren, Johan, Mats Nilsson, et Håkan Olsson. 2003. « Estimation of Tree Height and Stem Volume on Plots Using Airborne Laser Scanning ». *Forest Science* 49(3): 419-28. doi:10.1093/forestscience/49.3.419.

Hopkinson, Chris. 2007. « The influence of flying altitude, beam divergence, and pulse repetition frequency on laser pulse return intensity and canopy frequency distribution ». *Canadian Journal of Remote Sensing* 33(4): 312-24. doi:10.5589/m07-029.

- Huang, Huimin, Lanfen Lin, Ruofeng Tong, Hongjie Hu, Qiaowei Zhang, Yutaro Iwamoto, Xianhua Han, Yen-Wei Chen, et Jian Wu. 2020. « UNet 3+: A Full-Scale Connected UNet for Medical Image Segmentation ». *arXiv.org*. <https://arxiv.org/abs/2004.08790v1> (30 mai 2024).
- Hunter, Maria O., Michael Keller, Douglas Morton, Bruce Cook, Michael Lefsky, Mark Ducey, Scott Saleska, Raimundo Cosme de Oliveira Jr, et Juliana Schiatti. 2015. « Structural Dynamics of Tropical Moist Forest Gaps ». *PLOS ONE* 10(7): e0132144. doi:10.1371/journal.pone.0132144.
- INSEE. 2014. « Agriculture - L'exploitation du bois repart à la hausse – Bilan économique 2014 de Guyane | Insee ». <https://www.insee.fr/fr/statistiques/2018210?sommaire=2018217> (30 mai 2024).
- Kalinowski, Tomasz, Daniel Falbel, J. J. Allaire, François Chollet, RStudio, Google, Yuan Tang [ctb, et al. 2024. « keras: R Interface to “Keras” ». <https://cran.r-project.org/web/packages/keras/index.html> (27 août 2024).
- Kalinowski, Tomasz, Daniel Falbel, J. J. Allaire, Yuan Tang, Kevin Ushey, RStudio, et Google Inc. 2024. « tfdatasets: Interface to “TensorFlow” Datasets ». <https://cran.r-project.org/web/packages/tfdatasets/index.html> (27 août 2024).
- Khosravipour, Anahita, Andrew K. Skidmore, et Martin Isenburg. 2016. « Generating Spike-Free Digital Surface Models Using LiDAR Raw Point Clouds: A New Approach for Forestry Applications ». *International Journal of Applied Earth Observation and Geoinformation* 52: 104-14. doi:10.1016/j.jag.2016.06.005.
- Khosravipour, Anahita, Andrew K. Skidmore, Martin Isenburg, Tiejun Wang, et Yousif A. Hussin. 2014. « Generating Pit-Free Canopy Height Models from Airborne Lidar ». *Photogrammetric Engineering & Remote Sensing* 80(9): 863-72. doi:10.14358/PERS.80.9.863.
- LeCun, Yann, Yoshua Bengio, et Geoffrey Hinton. 2015. « Deep Learning ». *Nature* 521(7553): 436-44. doi:10.1038/nature14539.
- Lenth, Russell V., Ben Bolker, Paul Buerkner, Iago Giné-Vázquez, Maxime Herve, Maarten Jung, Jonathon Love, et al. 2024. « emmeans: Estimated Marginal Means, aka Least-Squares Means ». <https://cran.r-project.org/web/packages/emmeans/index.html> (27 août 2024).
- Lim, Kevin, Paul Treitz, Michael Wulder, Benoît St-Onge, et Martin Flood. 2003. « LiDAR Remote Sensing of Forest Structure ». *Progress in Physical Geography: Earth and Environment* 27(1): 88-106. doi:10.1191/0309133303pp360ra.
- Mulatu, Kalkidan Ayele, Brice Mora, Lammert Kooistra, et Martin Herold. 2017. « Biodiversity Monitoring in Changing Tropical Forests: A Review of Approaches and New Opportunities ». *Remote Sensing* 9(10): 1059. doi:10.3390/rs9101059.
- Nazarova, Tatiana, Pascal Martin, et Gregory Giuliani. 2020. « Monitoring Vegetation Change in the Presence of High Cloud Cover with Sentinel-2 in a Lowland Tropical Forest Region in Brazil ». *Remote Sensing* 12(11): 1829. doi:10.3390/rs12111829.
- d'Oliveira, Marcus V. N., Stephen E. Reutebuch, Robert J. McGaughey, et Hans-Erik Andersen. 2012. « Estimating forest biomass and identifying low-intensity logging areas using airborne

- scanning lidar in Antimary State Forest, Acre State, Western Brazilian Amazon ». *Remote Sensing of Environment* 124: 479-91. doi:10.1016/j.rse.2012.05.014.
- Pearson, Timothy R. H., Sandra Brown, Lara Murray, et Gabriel Sidman. 2017. « Greenhouse Gas Emissions from Tropical Forest Degradation: An Underestimated Source ». *Carbon Balance and Management* 12(1): 3. doi:10.1186/s13021-017-0072-2.
- Pereira, Rodrigo, Johan Zweede, Gregory P. Asner, et Michael Keller. 2002. « Forest canopy damage and recovery in reduced-impact and conventional selective logging in eastern Para, Brazil ». *Forest Ecology and Management* 168(1): 77-89. doi:10.1016/S0378-1127(01)00732-0.
- Putz, Francis E., et Michelle A. Pinard. 1993. « Reduced-Impact Logging as a Carbon-Offset Method ». *Conservation Biology* 7(4): 755-57.
- Putz, Francis E., Pieter A. Zuidema, Michelle A. Pinard, Rene G. A. Boot, Jeffrey A. Sayer, Douglas Sheil, Plinio Sist, Elias, et Jerome K. Vanclay. 2008. « Improved Tropical Forest Management for Carbon Retention ». *PLOS Biology* 6(7): e166. doi:10.1371/journal.pbio.0060166.
- Rangel Pinagé, Ekena, Michael Keller, Paul Duffy, Marcos Longo, Maiza dos-Santos, et Douglas Morton. 2019. « Long-Term Impacts of Selective Logging on Amazon Forest Dynamics from Multi-Temporal Airborne LiDAR ». *Remote Sensing* 11(6): 709. doi:10.3390/rs11060709.
- Ronneberger, Olaf, Philipp Fischer, et Thomas Brox. 2015. « U-Net: Convolutional Networks for Biomedical Image Segmentation ». *arXiv.org*. <https://arxiv.org/abs/1505.04597v1> (30 mai 2024).
- Roussel, Jean-Romain, Jean-François Bourdon, Ilythia D. Morley, Nicholas C. Coops, et Alexis Achim. 2022. « Correction, Update, and Enhancement of Vectorial Forestry Road Maps Using ALS Data, a Pathfinder, and Seven Metrics ». *International Journal of Applied Earth Observation and Geoinformation* 114: 103020. doi:10.1016/j.jag.2022.103020.
- Roussel, Jean-Romain, Jean-François Bourdon, Ilythia D. Morley, Nicholas C. Coops, et Alexis Achim. 2023. « Vectorial and topologically valid segmentation of forestry road networks from ALS data ». *International Journal of Applied Earth Observation and Geoinformation* 118: 103267. doi:10.1016/j.jag.2023.103267.
- Roussel, Jean-Romain, John Caspersen, Martin Béland, Sean Thomas, et Alexis Achim. 2017. « Removing bias from LiDAR-based estimates of canopy height: Accounting for the effects of pulse density and footprint size ». *Remote Sensing of Environment* 198: 1-16. doi:10.1016/j.rse.2017.05.032.
- Sader, Steven A. 1990. « Remote Sensing of Tropical Forests: An I Overview of Research and Applications Using 1 Non-Photographic Sensors ». *PHOTOGRAMMETRIC ENGINEERING*.
- Sherba, Jason, Leonhard Blesius, et Jerry Davis. 2014. « Object-Based Classification of Abandoned Logging Roads under Heavy Canopy Using LiDAR ». *Remote Sensing* 6(5): 4043-60. doi:10.3390/rs6054043.
- Silva, Carlos A., Ruben Valbuena, Ekena R. Pinagé, Midhun Mohan, Danilo R. A. de Almeida, Eben North Broadbent, Wan Shafrina Wan Mohd Jaafar, et al. 2019. « ForestGapR: An r Package for Forest Gap Analysis from Canopy Height Models ». *Methods in Ecology and Evolution* 10(8): 1347-56. doi:10.1111/2041-210X.13211.

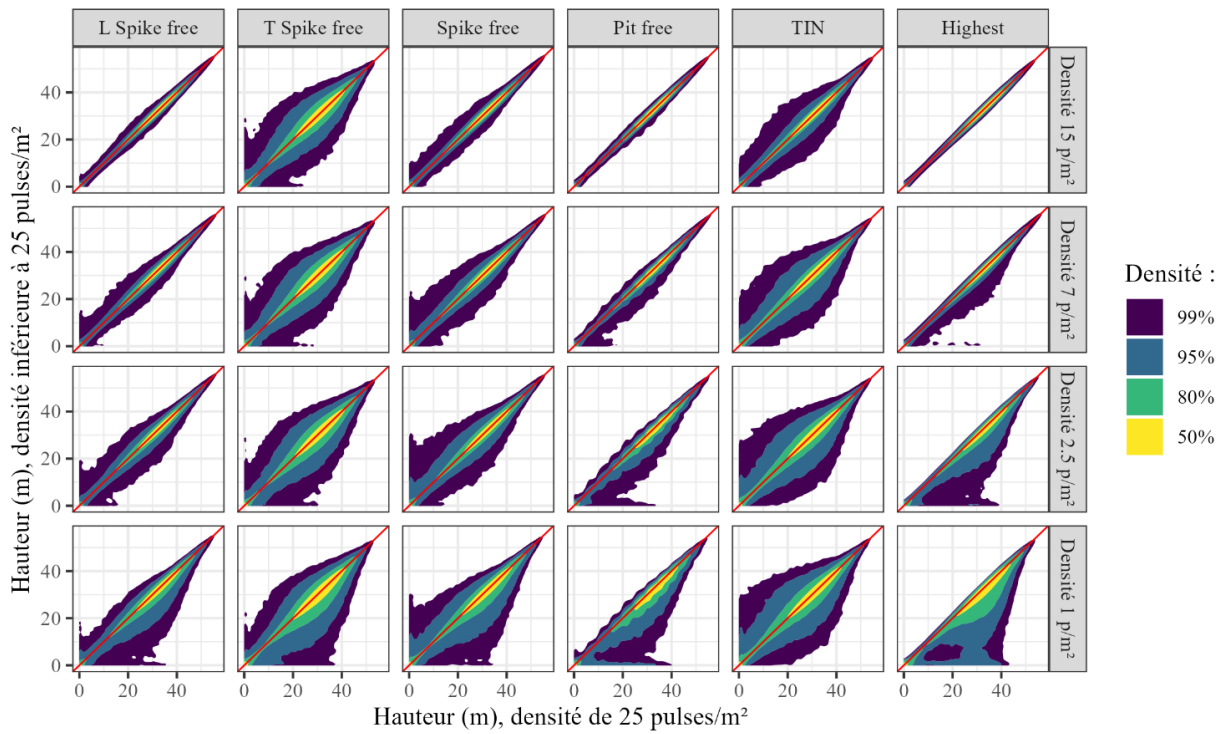
- Štular, Benjamin, Edisa Lozić, et Stefan Eichert. 2023. « Interpolation of airborne LiDAR data for archaeology ». *Journal of Archaeological Science: Reports* 48: 103840. doi:10.1016/j.jasrep.2023.103840.
- Thonnel, Audrey, Sébastien Sant, et Arthur Brisse. 2023. *Atlas de la Biodiversité Communale de Saül - Rapport de synthèse*. Parc amazonien de Guyane.
- Toumazet, Jean-Pierre, François-Xavier Simon, et Alfredo Mayoral. 2021. « Self-Adaptive Local Relief Enhancer (SAILORE): A New Filter to Improve Local Relief Model Performances According to Local Topography ». *Geomatics* 1(4): 450-63. doi:10.3390/geomatics1040026.
- Zhang, Rongyu, Lixuan Du, Qi Xiao, et Jiaming Liu. 2020. « Comparison of Backbones for Semantic Segmentation Network ». *Journal of Physics: Conference Series* 1544(1): 012196. doi:10.1088/1742-6596/1544/1/012196.

Annexes

Annexe 1 : Compléments graphiques pour la compréhension du comportement de la sensibilité des méthodes de CHM à la réduction de la densité de pulses.

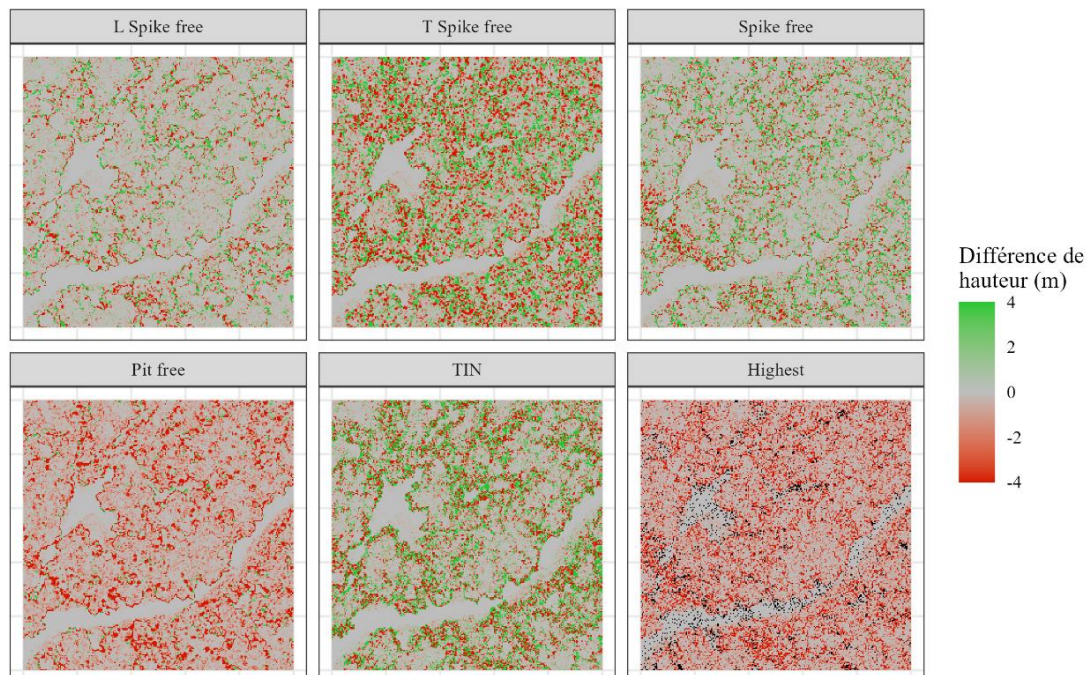
Impact de la dégradation des pulses d'un nuage de points sur la précision des types de CHM

Données : CCO495, 2021 | Echantillon : 10% des pixels



Différence de hauteur de CHM entre une densité de pulses de 25p/m² et de 2.5p/m²

Données : CCO495, 2021



Annexe2 : Détail du fonctionnement des modèles de segmentation par U-Net

L'ossature générale du modèle U-Net et de ses améliorations repose sur la succession d'un encodeur et d'un décodeur. L'architecture de l'encodeur est en réalité celle d'un CNN (Convolutional Neural Network). C'est une alternance de blocs convolutifs et de sous-échantillonnage par pooling. Cette étape est responsable de l'extraction des caractéristiques importantes d'une image donnée en entrée du modèle. Chaque bloc convolutif applique un certain nombre de convolutions, utilisant un kernel dont les poids sont initialisés aléatoirement. Ces poids sont ensuite ajustés pendant l'entraînement pour optimiser la capacité du modèle à extraire des caractéristiques pertinentes. En appliquant ces convolutions, le modèle génère plusieurs cartes de caractéristiques, qui représentent différents aspects de l'image d'entrée.


Après l'application des convolutions, les cartes de caractéristiques sont traitées par une fonction d'activation, généralement la ReLU (Rectified Linear Unit), pour introduire de la non-linéarité et permettre au modèle de modéliser des relations complexes entre les caractéristiques extraites. Ensuite, une opération de max pooling est effectuée, appliquant un filtre de 2x2 pour réduire la dimension spatiale des cartes de caractéristiques par un facteur de 2. Cela permet de conserver les informations structurelles de l'image tout en réduisant le nombre de pixels, facilitant ainsi l'extraction des caractéristiques essentielles. Ce processus est répété dans l'encodeur jusqu'à ce que la réduction de la résolution spatiale atteigne un point où les caractéristiques générales de l'image d'origine peuvent être suffisamment mises en évidence sans perte excessive d'informations cruciales.

À la suite de la phase d'encodage de l'image initiale vient la phase de reconstruction de l'image par décodage des caractéristiques extraites par l'encodeur. Cette phase inverse l'encodage en remplaçant les étapes de sous-échantillonnage par des étapes de suréchantillonnage, afin de retrouver progressivement les dimensions de l'image initiale. Le suréchantillonnage s'effectue grâce à des couches de déconvolution qui augmentent la dimension spatiale des cartes de caractéristiques, permettant ainsi de reconstruire l'image à partir de ses caractéristiques compressées. Pour garantir une bonne reconstruction de l'image et préserver les détails fins, le U-Net utilise des connexions de saut qui récupèrent les cartes de caractéristiques des blocs convolutifs de l'encodeur et les concatènent avec celles du décodeur. Cette concaténation aide à récupérer les informations pouvant être perdues lors des étapes de réduction de résolution et assure une meilleure précision dans la segmentation finale. La spécificité du modèle U-Net 3+ réside dans l'utilisation de connexions plus denses entre les blocs convolutifs, permettant de mieux prendre en compte les éléments fins et d'améliorer la qualité de la reconstruction. La sortie de la phase de décodage est une image segmentée ayant les mêmes dimensions

que l'image d'entrée. Le modèle U-Net est particulièrement efficace pour les tâches de segmentation, car il parvient à combiner les informations contextuelles globales et les détails locaux.

Comme tous les modèles supervisés, les U-Net nécessitent des données étiquetées pour permettre à la machine d'apprendre. Ils comparent leurs sorties à des masques de vérité, ce qui leur permet d'estimer les erreurs via une ou plusieurs fonctions de perte. Le calcul de la perte aide le modèle à ajuster les poids des convolutions, ce qui améliore les prédictions futures. À chaque itération, elle fournit un signal de rétroaction utilisé pour ajuster les poids des couches convolutives grâce à un algorithme d'optimisation. Ainsi, sans prendre en compte le problème de surapprentissage, la capacité prédictive du modèle augmente avec le nombre d'époques d'entraînement. Dans la plupart des modèles d'apprentissage supervisé, les fonctions de perte et les métriques servent à guider l'apprentissage et évaluer la performance du modèle. La fonction de perte quantifie la différence entre les prédictions du modèle et les valeurs des masques de vérité. Tandis que les métriques sont utilisées pour évaluer la performance du modèle de manière plus interprétable. Les métriques ne sont pas utilisées pour ajuster les poids pendant l'entraînement.


Composition résumant la segmentation au sein d'un modèle U-Net




Annexe 3 : Impact de la densité de pulses sur la qualité de la segmentation de la desserte forestière

Comparaison entre la qualité de la segmentation du réseau de desserte et le nombre de pulses par m²


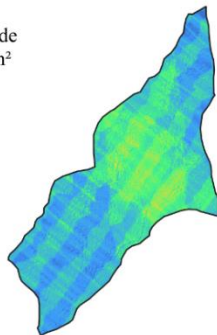
HKO 096
Densité globale de
pulses : 5.37 m²





CCO 465
Densité globale de
pulses : 9.04 m²




SAO 504
Densité globale de
pulses : 37.10 m²



CCO 495
Densité globale de
pulses : 52.62 m²



□ Limite de la parcelle



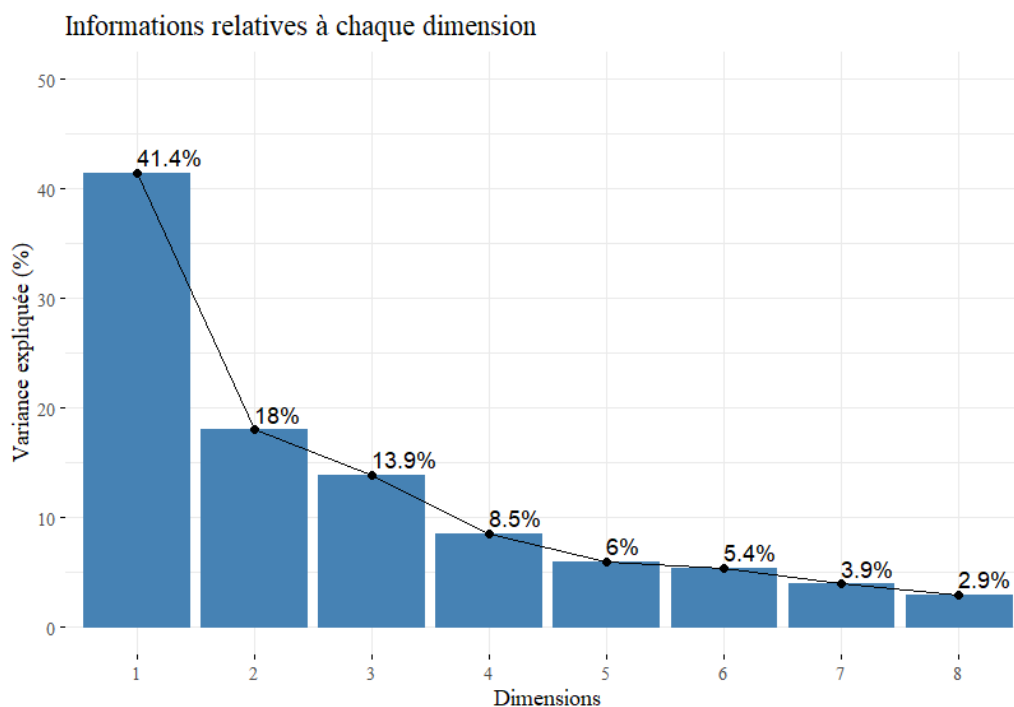
- Classes :
- Arrière-plan
 - Routes ONF / Pistes à camions
 - Pistes principales / Pistes secondaires

Annexe 4 : Table dérivant les paramètres de distribution des variables extraite dans la partie 5

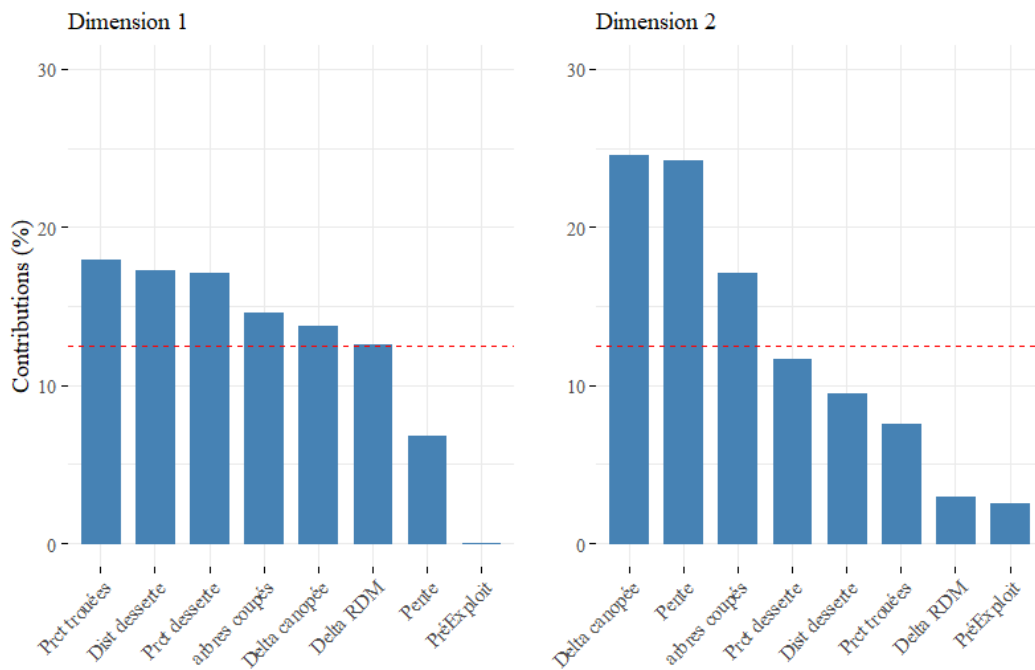
Variable	N	Moyenne	sd	Min	Pctl 25	Pctl 75	Max
Pente	4064	8,8	4,3	2,1	5	12	25
sd canopée pre	4064	7,5	1,6	3,4	6,4	8,5	14
Delta canopée	4064	-2,1	2,4	-14	-3,5	-0,38	4,2
Delta RDM	4064	44	13	-11	35	53	83
Dist desserte	4064	26	23	1,6	8,9	35	204
Prct trouées	4064	11	10	0	3,6	16	88
Prct desserte	4064	11	13	0	0	21	61
Arbres coupes	4064	1,2	1,3	0	0	2	8
Exploitant	N	%					
SEFEG/ PIR2	2412	59%					
SFA	1652	41%					
Autre	0	0%					

Annexe 5 : Description graphique de la variance expliquée par les dimensions 1 et 2 de l'ACP.

Description de la contribution des variables pour la construction des variables 1 et 2




Contribution des variables aux dimensions 1 et 2



Annexe 6 : Distribution des résidus du modèle linéaire issue de l'AIC pour l'ajustement des moyennes du pourcentage d'ouverture de la canopée

Distribution des résidus du modèle issue de l'AIC



Synthèse méthodologique, de la génération des modèles numériques à l'analyse statistique

