



# Télédétection des déperissements forestiers par imagerie Sentinel-2 en Guyane Française

## RAPPORT DE STAGE **LEVISTRE MANON**

Office national des forêts (ONF) - Direction territoriale Guyane - Pôle Recherche, Développement, Innovation (RDI)

**Encadrement : Jérémy Commins**

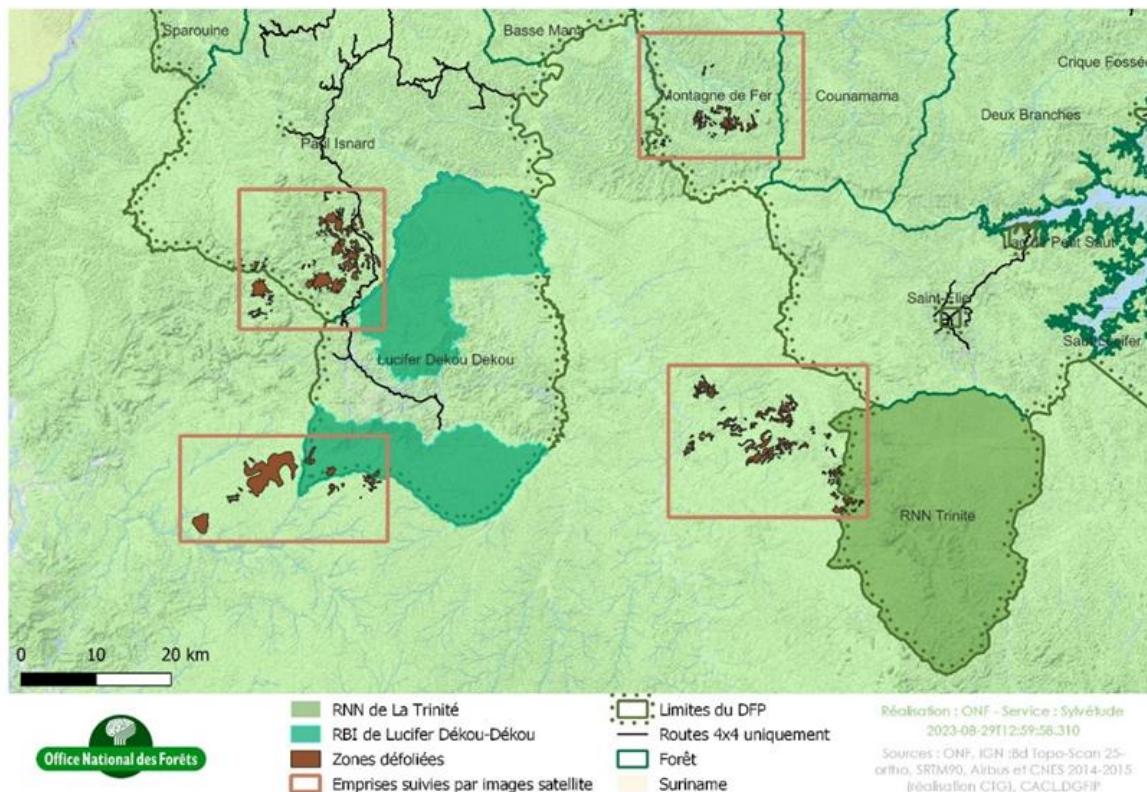
## **Sommaire**

Introduction.....	1
Les dépréisements forestiers.....	2
Historique et définition .....	2
Facteurs contribuant aux dépréisements en Amazonie .....	3
Détection et cartographie des dépréisements forestiers.....	5
Données in situ .....	5
Données de télédétection .....	6
1. Vecteurs .....	6
2. Capteurs.....	6
Méthodes d'analyse des images.....	9
Matériel et méthode.....	11
Données.....	11
Méthodologie .....	12
Résultats .....	18
Discussion .....	25

## Introduction

Depuis septembre 2022, plusieurs zones de dépérissement forestier ont été identifiées dans les forêts de Guyane Française. Ces zones concernent notamment le nord-ouest de la réserve naturelle nationale de la Trinité, le sud de la réserve biologique intégrale Lucifer Dékou-Dékou, ainsi que deux secteurs du domaine forestier permanent situés dans les forêts domaniales de Paul Isnard et de Montagne de Fer (Cf. Figure 1).

**Figure 1 : Carte de localisation du phénomène de dépérissement**



Les défoliations propres à ces zones de dépérissement concerneraient une surface de l'ordre de 10 000 ha, touchent autant la canopée que le sous-bois et ne concernent que des forêts de terre ferme. Ce phénomène pourrait être en lien avec l'intensification de l'ENSO (El Niño Southern Oscillation), alternant des saisons sèches sévères en période El Niño et des saisons des pluies très marquées pendant la Niña.

Ces dépérissements constituent une pression supplémentaire à celles résultant directement des activités humaines telles que la déforestation et l'exploitation minière. Cette combinaison de pressions met en péril la biodiversité de la forêt amazonienne, menaçant la richesse écologique unique de cet écosystème ainsi que les services essentiels qu'il fournit à l'humanité, tels que la régulation du climat et la fourniture de ressources alimentaires et médicinales.

Dans ce contexte, l'établissement d'une méthode de cartographie précise des zones touchées par ces dépérissements permettrait de quantifier ce phénomène, son évolution et potentiellement d'en identifier les causes. Pour se faire, la télédétection, en particulier à l'aide des images Sentinel-2, constitue un outil précieux en permettant de surveiller de vastes zones forestières. La méthodologie adoptée dans cette étude repose sur l'utilisation d'algorithmes de Machine Learning, notamment la méthode de classification Random Forest, pour analyser les images Sentinel-2. Cette approche inclut les étapes de prétraitement des données, production d'indices de végétation et spectraux, classification des images, validation des résultats à l'appui des acquisitions Pléiades.

L'objectif principal ici est d'exploiter le potentiel de la télédétection par imagerie Sentinel-2 pour fournir une cartographie détaillée des zones de dépérissement forestier en Guyane Française. Ceci permettrait de mieux comprendre les dynamiques spatiales et temporelles de ces phénomènes et d'investiguer les causes possibles du dépérissement. A terme la poursuite de ces travaux permettrait de proposer des solutions de gestion et de restauration des zones affectées.

## Les dépérissements forestiers

### Historique et définition

Les dépérissements forestiers ne sont pas des phénomènes nouveaux, ils sont documentés depuis plusieurs siècles et leur définition a connu différentes évolutions. [Landmann \(1994\)](#) rapporte la définition de [Mueller-Dombois \(1986\)](#) du dépérissement tel qu'un phénomène de sénescence collective synchrone entraînée par une perturbation soudaine. Cette définition évolue ensuite pour prendre en compte la multiplicité potentielle des facteurs de dépérissement jusqu'à être caractérisé par un ensemble d'anomalies perceptibles à l'œil sur le terrain, telles que la mortalité ou la réduction de la qualité et de la quantité de feuillage ([Delatour, 1990](#) ; [Landmann, 1994](#)). Delatour (1990) apporte aussi une prise en compte de l'évolution au cours du temps du phénomène qui traduit le fait que l'issu naturelle pour l'arbre dépérisant est jugée problématique mais pas obligatoirement fatale. Cette définition semble être en accord avec la définition contemporaine qui décrit une dégradation progressive de l'état de santé d'une forêt entraînant le plus souvent la mort des arbres nécessitant une intervention rapide : surveillance renforcée, exploitation des arbres malades... ([ONF, 2023](#)).

[Landmann \(1994\)](#) distinguait trois grands types de facteurs intervenant dans les dépérissements : les facteurs prédisposants contribuant à l'affaiblissement général de l'arbre au long terme dont le changement climatique est un exemple ; les facteurs déclenchants agissant de façon intense sur une relativement courte période (ex : sécheresse, insectes défoliateurs) et les facteurs aggravants accentuant la perturbation (facteurs biotiques, champignons ou insectes). Dans la littérature scientifique

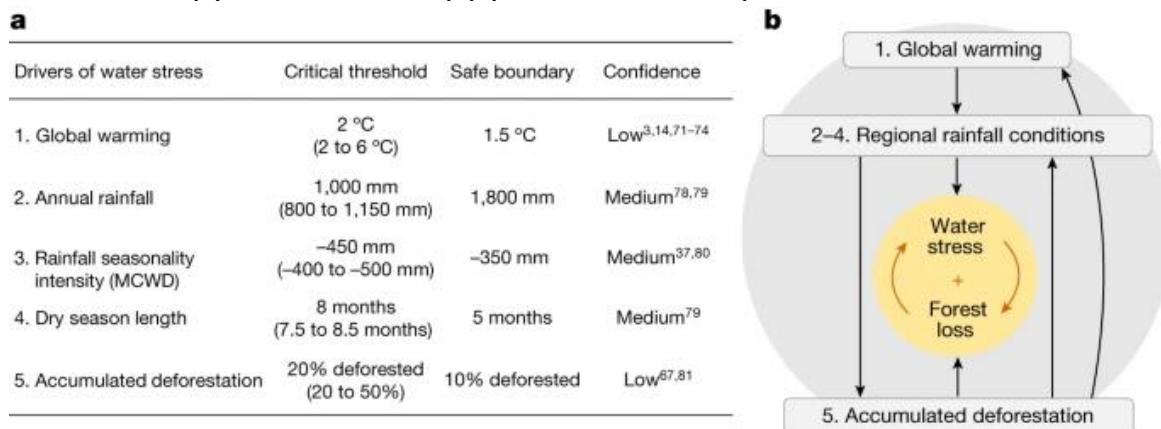
contemporaine, il semble que cette distinction ne soit plus d'actualité, les dépérissements liés aux parasites et aux sécheresses semblent être les plus récurrents, ils sont en tous cas les plus documentés ([ONF, 2023](#) ; [Torres et al., 2021](#)).

### Facteurs contribuant aux dépérissements en Amazonie

Les dépérissements en Guyane, et plus largement en Amazonie, peuvent eux aussi être dus à différents facteurs souvent interconnectés. Parmi eux, reviennent le plus souvent des facteurs abiotiques en lien avec le changement climatique tels que :

- Les épisodes de sécheresse, à eux seuls ou accompagnés de facteurs tels que les incendies de forêt et fortement influencés par l'ENSO (El Niño–Southern Oscillation) ([Allen et al., 2017](#) ; [Jump et al., 2017](#) ; [McDowell, Allen and Anderson-Teixeira, 2018](#)). [Costa et al., \(2023\)](#) indiquent que les forêts où la nappe phréatique est peu profonde peuvent être plus résilientes face à des sécheresses d'intensité moyenne, mais pourraient être plus sensibles lors de sécheresses importantes. De manière plus générale, l'augmentation du stress hydrique jusqu'à un certain seuil (Cf. Figure 2 ci-dessous) pourrait, d'ici 2050, entraîner un changement d'écosystème pour 10% à 47% des forêts amazoniennes ([Flores et al., 2024](#)).

**Figure 2 : Facteurs de stress hydrique sur la forêt amazonienne, leurs seuils critiques, limites de sécurité (a) et interactions (b) (Flores et al., 2024).**



Dans ce scénario, les trois écosystèmes résultants pourraient être : des savanes de sable blanc, des canopées ouvertes dégradées, ou des forêts dégradées, selon les conditions environnementales et d'autres facteurs ([Flores et al., 2024](#)).

Les précipitations et l'engorgement des sols sont aussi mis en avant comme facteurs de dépérissement. En effet, [Laurance et al., \(2009\)](#) rapportent que la mortalité des arbres atteint son pic pendant les périodes anormalement humides, au cours desquelles le recrutement et la croissance des arbres diminuent. Les inondations peuvent provoquer une mortalité locale des arbres indépendamment de leur taille ([Laurance et](#)

[al., 2009](#)). D'autre part, les forêts tropicales et les savanes peuvent représenter des états stables alternatifs dans certaines conditions environnementales. Le double stress causé à la fois par la sécheresse et l'engorgement en eau favorise la transition vers des écosystèmes de savanes [\(Mattos et al., 2023\)](#). De même, les conclusions de [Staal et al., \(2016\)](#) suggèrent que les modifications des schémas de précipitations pourraient entraîner des déplacements spatiaux des limites entre les forêts et les savanes lorsque des seuils critiques sont approchés. Ces seuils sont définis par 1760 mm de précipitations annuelles moyennes et un indice de saisonnalité de Markham\* (MSI) de 50 %, correspondant à une distribution de la totalité des précipitations annuelles sur 6 mois et calculé comme suit :

$$MSI = 100 \frac{\sqrt{\left[ \sum_m P_m \sin\left(m \frac{2\pi}{12}\right)^2 \right] + \left[ \sum_m P_m \cos\left(m \frac{2\pi}{12}\right)^2 \right]}}{\sum_m P_m} \quad \text{(Staal et al., 2016).}$$

Ces épisodes de sécheresse ou de précipitations intenses, favorables au déclin forestier en Amazonie ont lieu dans un contexte d'oscillation climatiques interannuelles connues sous le nom de El Niño Southern Oscillation (ENSO). L'ENSO est un phénomène climatique naturel à grande échelle qui se caractérise par des fluctuations de la température de l'océan (El Niño et La Niña), ainsi que par des changements dans l'atmosphère sus-jacente (oscillation australe) [\(El Niño-oscillation australe \(ENSO\), no date\)](#). Les variations des précipitations et de la température induites par l'ENSO se produisent selon des cycles irréguliers de 2 à 7 ans et joueraient un rôle plus important dans les activités végétales des forêts tropicales que le rayonnement solaire en surface [\(Nagai, Ichii and Morimoto, 2007\)](#). [Zemp et al. \(2017\)](#) soulignent que ces perturbations ont le potentiel de déstabiliser de vastes portions de la forêt amazonienne, notamment en favorisant la mise en place une boucle de rétroaction positive basée sur les interactions entre la végétation et l'atmosphère.

Outre les impacts climatiques directs, des facteurs liés aux changements globaux, tels que l'augmentation du CO<sub>2</sub> atmosphérique, peuvent également influencer la santé des écosystèmes forestiers amazoniens. Par exemple, l'augmentation du CO<sub>2</sub> peut induire une fertilisation qui entraîne un éclaircissement des peuplements ou une accélération de la croissance des arbres, les amenant à atteindre des hauteurs plus importantes et donc plus vulnérables [\(McDowell et al., 2018\)](#). L'incertitude associée aux effets à long terme du CO<sub>2</sub> est beaucoup plus grande que celle associée aux changements de précipitations [\(Rammig et al., 2010\)](#). Ce qui souligne que l'importance des effets directs du CO<sub>2</sub> sur les écosystèmes tropicaux est assez méconnue.

Enfin, d'autres facteurs peuvent contribuer à une surmortalité localisée des arbres en forêt tropicale humide tels que les feux de forêts, le vent, les agents biotiques et les lianes bien que leur part relative dans les déclinements des forêts tropicales humides et leurs interactions soient sous-étudiées [\(McDowell et al., 2018\)](#).

## Détection et cartographie des dépérissements forestiers

La télédétection se réfère à la technique d'observation et de collecte de données à distance, souvent à partir de satellites ou de plateformes aéroportées, sans qu'il soit nécessaire d'entrer en contact direct avec la zone étudiée. Utile dans l'étude des dépérissements forestiers, elle se concentre principalement sur l'observation de la défoliation et du brunissement de la canopée et offre un avantage majeur grâce à la possibilité d'acquérir de manière répétée des informations standardisées sur de vastes zones pour un faible coût et avec une haute fréquence ([Pause et al., 2016](#)). La recherche tend à se focaliser sur les dépérissements associés à des facteurs de stress spécifiques, tandis qu'un nombre limité d'études cherchent à établir des dispositifs d'alerte précoce. De plus, bien que les forêts tropicales occupent une grande partie des terres forestières de la planète et abritent une grande biodiversité, elles sont sous-représentées dans la littérature scientifique ([Torres et al., 2021](#)). Cette sous-représentation peut être attribuée à la forte couverture nuageuse présente une grande partie de l'année dans ce biome, ce qui limite la possibilité de mener des études utilisant des méthodes optiques qui sont pourtant souvent privilégiées. Néanmoins, la technologie radar peut offrir de meilleures performances dans de telles conditions, mais elle est rarement appliquée dans les biomes tropicaux ([Torres et al., 2021](#)).

### Données in situ

Des données terrains sont fréquemment utilisées pour valider et affiner les observations obtenues par télédétection dans le cadre de la détection des dépérissements forestiers. Elles peuvent concerner directement les arbres et leur état voire leur degré de dépérissement qui s'exprime le plus souvent par l'importance de la défoliation ([Akashi and Mueller-Dombois, 1995](#); [Dezzeo, Hernández and Fölster, 1997](#); [Pontius, 2014](#); [Bhattarai et al., 2020](#)) ou se concentrer sur les facteurs de stress dont la part de responsabilité vis-à-vis du dépérissement est étudiée (ex. données météo) ([Pau, Okin and Gillespie, 2010](#)).

Cependant, l'accès et l'utilisation des données terrain peut présenter des défis, notamment en lien avec leur qualité (méthode d'échantillonnage ou disponibilité spatiale) ; leur quantité (disponibilité spatiale et temporelle) les restrictions politiques et commerciales sur la disponibilité des données ([Pause et al., 2016](#)). Considérant ces difficultés, qui peuvent être exacerbées dans des environnements forestiers denses comme ceux de la Guyane française, certaines études développent une méthodologie qui tente de s'affranchir de l'utilisation de données terrain ([Spruce et al., 2011](#)) ou les complètent via l'utilisation de données issues de capteurs aéroportés ([Huete et al., 2002](#)).

## Données de télédétection

### *1. Vecteurs*

Les capteurs embarqués sur des vecteurs aéroportés (pilotés ou non) et sur des plates-formes terrestres fournissent des données à résolution spatiale souvent plus élevées que les données satellitaires. Cependant, ils sont davantage limités en termes de couverture spatiale et temporelle et sont généralement plus coûteux. Bien que leur utilisation ne soit pas prédominante dans ce domaine, elle est en augmentation ([Torres et al., 2021](#)).

D'autre part, les acquisitions satellitaires se démarquent en raison de leur couverture spatiale exhaustive, de leur catalogue de données historiques, ainsi que par la résolution spatiale élevée de certaines d'entre elles. L'accès libre à un grand nombre de ces données et leur pertinence dans l'évaluation de différents paramètres de santé des forêts, en font les plus couramment utilisées ([Torres et al., 2021](#)).

### *2. Capteurs*

Les capteurs optiques (passifs ou LiDAR) fournissent des informations pertinentes pour l'étude des déprésissements forestiers, mais leur capacité à pénétrer à travers le couvert est limitée par la nébulosité, notamment en zone tropicale. Les capteurs multispectraux ont cependant démontré leur potentiel pour évaluer des indicateurs de santé des forêts tels que le contenu en eau, la décoloration des feuilles, l'indice de surface foliaire et le contenu en pigments, et sont les plus utilisés dans ce domaine d'étude ([Pontius, 2014](#) ; [Bhattarai et al., 2020](#) ; [Cavender-Bares, Gamon and Townsend, 2020](#) ; [Gonçalves et al., 2020](#) ; [Torres et al., 2021](#)). Plusieurs zones du spectre électromagnétique sont importantes pour l'étude de la végétation et en particulier des déprésissements forestiers (Cavender-Bares, Gamon and Townsend, 2020 ; Torres et al., 2021):

- La région visible (0,4–0,7  $\mu\text{m}$ ), où la végétation présente une faible réflectance due à l'absorption de la lumière par les pigments.
- À la frontière entre la région visible et le proche infrarouge se trouve le bord rouge, particulièrement pertinent pour estimer le contenu en chlorophylle et en azote de la végétation, car il marque la transition entre l'absorption élevée de la chlorophylle dans le rouge et l'absorption faible dans le proche infrarouge (NIR).
- La région proche infrarouge (NIR 0,7–1,2  $\mu\text{m}$ ) présente des valeurs de réflectance plus élevées pour la végétation, notamment en raison de la structure cellulaire des feuilles.
- Enfin, le moyen infrarouge est divisé en infrarouge à ondes courtes ou SWIR (1,2–2,5  $\mu\text{m}$ ) et moyen infrarouge (2,5–8  $\mu\text{m}$ ). Le SWIR présente un potentiel d'utilisation dans la mesure du contenu en humidité, notamment grâce à ses caractéristiques d'absorption et de réflectance spécifiques.

Les informations contenues dans ces différents domaines du spectre électromagnétique sont souvent utilisées pour évaluer des caractéristiques telles que l'abondance et la couleur des feuilles ainsi que l'humidité de la canopée. Le NDVI (Normalized Difference Vegetation Index) est l'un des indices les plus couramment utilisés à cette fin. Cependant, il présente des limitations importantes dans les environnements de végétation dense comme la forêt amazonienne en raison de la saturation qui se produit lorsque la valeur de l'indice atteint un certain seuil au-delà duquel sa capacité à différencier les niveaux de biomasse n'est plus assurée. ([Huete et al., 2002](#) ; [Pau, Okin and Gillespie, 2010](#)). Pour remédier à ce problème, d'autres indices tels que l'EVI (Enhanced Vegetation Index), le kNDVI, et d'autres encore, ont été proposés ([Camps-Valls et al., 2021](#)). De manière plus générale, des études ont été menées pour développer et tester des indices de végétation et d'humidité reflétant des paramètres spécifiques du couvert végétal utiles à la télédétection des déprésissements forestier tels que l'indice de surface foliaire (LAI) et la teneur en chlorophylle et en caroténoïdes foliaire ([Pontius, 2014](#); [Bhattarai et al., 2020](#); [Gonçalves et al., 2020](#); [Moreno-Fernández et al., 2021](#)). Le tableau ci-dessous (Fig. 3) présente de manière non exhaustive des indices spectraux pouvant permettre ou faciliter la détection des déprésissements en forêt tropicale humide.

**Figure 3 : Synthèse des indices utilisés pour la classification des déprésissements forestiers en milieu tropical à partir de l'imagerie Sentinel-2**

Indice	Formule	Caractéristiques	References
Aoki (Aoki Index)	B3 / B8	Taux de chlorophile	(Pontius, 2014)
CARI (Chlorophyll Absorption Ratio Index)	B5 / B3 - 1	Humidité de la canopée, LAI(leaf area index), biomasse totale	(Huang et al., 2018)
CSI (Canopy Structure Index)	2.5 * ((B8 - B5) / (B8 + B5)) * (B2 / B5)		(Zhang et al., 2022)
EVI (Enhanced Vegetation Index)	2.5 * (B8 - B4) / (B8 + 6 * B4 - 7.5 * B2 + 1)	Couverture de la canopée, verdure	(Moreno-Fernández et al., 2021) (Gonçalves et al., 2020) (Cavender-Bares, Gamon and Townsend, 2020), (EVI (Enhanced Vegetation Index)   Sentinel Hub custom scripts)
GCC (Green Chromatic Coordinate)	B2 / (B4 + B3 + B2)	Abondance des feuilles de moins d'un mois	(Gonçalves et al., 2020)
IRECI (Inverted Red-Edge Chlorophyll Index)	(B7 - B4) * (B6 / B5)	Défoliation légère	(Bhattarai et al., 2020)
kNDVI (Kernel Normalized Difference Vegetation Index)	$\tanh(((B8 + B4) / (B8 - B4))^2)$	Verdure, et robuste au problème de saturation du NDVI	(Camps-Valls et al., 2021)

MCARI (Modified Chlorophyll Absorption in Reflectance Index)	$((B5 - B4) - 0.2 * (B5 - B3)) * (B5 / B4)$	Défoliation légère	(Bhattarai <i>et al.</i> , 2020), (Sinergise)
MCARI2 (Modified Chlorophyll Absorption in Reflectance Index 2)	$1.5 * ((2.5 * (B8 - B4)) - (1.3 * (B8 - B3))) / \text{sqrt}((2 * B8 + 1)^2) - (6 * B8 - 5 * (B4^2) - 0.5))$	LAI	(Pontius, 2014)
MSR (Modified Simple Ratio)	$((B7 / B4) - 1) / \text{sqrt}((B7 / B4) + 1)$	Défoliation légère	(Bhattarai <i>et al.</i> , 2020)
NDII11 (Normalized Difference Infrared Index 11)	$(B8A - B11) / (B8A + B11)$	Défoliation légère	(Bhattarai <i>et al.</i> , 2020)
NDMI (Normalized Difference Moisture Index)	$(B8 - B11) / (B8 + B11)$	Déclin de la végétation en période de sécheresse	(Moreno-Fernández <i>et al.</i> , 2021)
NDVI (Normalized Difference Vegetation Index)	$(B8 - B4) / (B8 + B4)$	Verture	(Moreno-Fernández <i>et al.</i> , 2021) (Camps-Valls <i>et al.</i> , 2021), (Spruce <i>et al.</i> , 2011)
NBR (Normalized Burn Ratio)	$(B8A - B12) / (B8A + B12)$	Déclin de la végétation en lien avec la sécheresse	(Losso <i>et al.</i> , 2022)
RARSc (Red-Edge Atmospheric Resistant Stress Index)	B7 / B2		(Scheel, 2018)
SAVI (Soil Adjusted Vegetation Index)	$(B8 - B4) / (B8 + B4 + 0.5) * (1 + 0.5)$	Verture	(Moreno-Fernández <i>et al.</i> , 2021)
TCW (Tasseled Cap Wetness)	$0.1511 * B2 + 0.1973 * B3 + 0.3283 * B4 + 0.3407 * B8 - 0.7117 * B11 - 0.4559 * B12$	Déclin de la végétation en période de sécheresse	(Moreno-Fernández <i>et al.</i> , 2021)

Parmi les capteurs et plates-formes capables d'obtenir des informations à ces longueurs d'onde, on trouve Landsat, MODIS, le MSI de Sentinel-2, Worldview et RapidEye, ainsi que des capteurs hyperspectraux comme AVIRIS. Malgré la meilleure résolution temporelle et spatiale des images de Sentinel-2, Landsat reste la mission satellitaire la plus employée dans ce type d'étude en raison de la plus grande couverture temporelle des acquisitions ([Torres \*et al.\*, 2021](#)). On peut aussi mentionner les capteurs de très haute résolution spatiale, avec leur couverture limitée par image (10 à 20 km de largeur) qui conviennent donc uniquement à la cartographie locale et régionale ([Lausch \*et al.\*, 2016](#)).

D'autre part, les capteurs actifs se révèlent très utiles pour étudier la structure de la forêt à l'intérieur et sous la canopée, du fait de leur capacité à y pénétrer (contrairement aux capteurs passifs). Le SAR (Synthetic-aperture radar) peut fonctionner par temps

nuageux, ce qui n'est pas possible avec les capteurs optiques ou le LiDAR. Il est aussi sensible au stress hydrique et peut mettre en évidence la mortalité des arbres après des sécheresses sévères ([van Emmerik et al., 2017](#); [Saatchi et al., 2013](#)). Malgré tout, le potentiel des capteurs SAR dans ce domaine reste largement inexploité ([Torres et al., 2021](#)). Enfin, le LiDAR peut permettre de cartographier les arbres morts à l'échelle d'une parcelle. L'intégration des données LiDAR avec des données optiques multi- et hyperspectrales peut considérablement améliorer ces performances ([Bright et al., 2014](#); [Lausch et al., 2016](#)), ce qui est d'ailleurs valable en général pour l'intégration de données de différents vecteurs et/ou capteurs. En effet, plusieurs études explorent l'association de données provenant de différentes plates-formes ou capteurs pour tirer parti de leurs forces respectives ([Pontius, 2014](#); [Gonçalves et al., 2020](#)).

### Méthodes d'analyse des images

L'approche pixel, se base sur l'analyse de chaque pixel individuellement, elle est privilégiée pour son efficacité à offrir une vision d'ensemble des caractéristiques dans une image, à toutes les échelles ([Pau, Okin and Gillespie, 2010](#); [Garrity et al., 2013](#); [Bright et al., 2014](#)). D'autre part, l'approche objet qui se concentre sur les objets ou les structures dans une image, est utilisée de manière plus ciblée, notamment lorsque l'identification précise d'objets individuels est cruciale, et que des données à très haute résolution spatiale sont utilisées ([Gonçalves et al., 2020](#); [Torres et al., 2021](#)). Marginalement, [Berveglieri et al. \(2021\)](#) ont appliqué une approche par superpixel, regroupant des ensembles de pixels cohérents en entités uniques, pour simplifier la complexité des données dans l'analyse des tendances et des changements dans les trajectoires de succession des forêts tropicales à partir de séries temporelles d'images Landsat.

En fonction de la perspective et de l'approche de l'étude, des méthodes quantitatives (fournissant des données continues) ou qualitatives (fournissant le degré de dommage) sont utilisées. Selon l'approche choisie, différentes techniques de modélisation sont sélectionnées. La classification est utilisée dans les études qualitatives, tandis que la régression est plutôt utilisée pour une représentation quantitative des déperissements ([Dezzeo, Hernández and Fölster, 1997](#); [Pontius, 2014](#); [Bhattarai et al., 2020](#); [Fremout et al., 2022](#)). D'autres études utilisent l'analyse de corrélation, une approche physique (l'inversion des modèles de transfert radiatif) ou l'analyse de séries temporelles ([Torres et al., 2021](#)).

Un point notable est l'essor des études intégrant des techniques de Machine Learning (ML), où le Random Forest (RF) est l'algorithme prédominant, tant comme classificateur que comme algorithme de régression (Cavender-Bares, Gamon and Townsend, 2020; Torres et al., 2021). Le RF présente plusieurs avantages qui expliquent sa popularité. Il peut traiter des paramètres d'entrée de différents types, gérer de grands

ensembles de variables avec des interactions complexes (bien que les corrélations entre les variables et l'autocorrélation spatiale puissent affecter la précision des résultats), modéliser des relations complexes entre différentes variables et permettre de déterminer l'importance des variables prédictives (Lausch *et al.*, 2016; Torres *et al.*, 2021). Ces caractéristiques offrent une interprétation plus transparente de la structure du modèle et de la sensibilité des variables par rapport à d'autres méthodes ML, telles que les réseaux neuronaux artificiels ([Lausch \*et al.\*, 2016](#)). D'autre part, des études ont montré la supériorité du RF par rapport aux SVM (Support Vector Machine), autre modèle de ML utilisé pour la classification et la régression dans la construction de modèles ([Bhattarai \*et al.\*, 2020](#)).

[Dobrinić \*et al.\* \(2022\)](#) ont mis en avant les bonnes performances du MDA (Mean Decrease Accuracy) pour la sélection des variables dans un RF. En effet, cette méthode de sélection de variables donnait la meilleure précision avec le moins de variables possible parmi cinq méthodes de sélection étudiées, dont l'indice de Gini.

Enfin, L'analyse des séries temporelles d'images satellites permet d'améliorer ou de faciliter le suivi de l'évolution des déprésissements forestiers. D'une part, cette approche permet une surveillance quasi-temps réel sans nécessiter une collecte intensive de données sur le terrain comme précurseur (Spruce *et al.*, 2011). D'autre part, les algorithmes BFAST (Breaks For Additive Seasonal and Trend) et BEAST (Bayesian Estimator of Abrupt change, Seasonal change, and Trend) sont utilisé pour détecter les changements brusques dans les séries temporelles avec des composantes saisonnières et de tendance ([Berveglieri \*et al.\*, 2021](#); [Moreno-Fernández \*et al.\*, 2021](#)). Ces deux outils fournissent des moyens efficaces pour analyser les séries temporelles et comprendre les changements environnementaux, notamment dans la gestion des écosystèmes forestiers.

En somme, les déprésissements forestiers en Amazonie, tels que ceux observés en Guyane, résultent de divers facteurs interconnectés, notamment le changement climatique, les épisodes de sécheresse et les perturbations liées à l'ENSO. La télédétection, combinant des données satellites et des capteurs aéroportés, offre une approche efficace pour la cartographie et la surveillance de ces phénomènes. L'analyse des images, soutenue par des méthodes quantitatives et des techniques d'apprentissage automatique telles que le RF , permet de comprendre et de quantifier ces déprésissements, offrant ainsi des perspectives pour une gestion plus efficace des écosystèmes forestiers.

## Matériel et méthode

### Données

Ce travail s'est appuyé sur des images Sentinel 2 et Pléiades, respectivement des acquisitions optiques satellitaires de haute et très haute résolution spatiale (Cf. Figure 4).

Les images Sentinel 2 utilisées étaient corrigées au niveau L2A et toutes les bandes utilisées, rééchantillonnées par interpolation bilinéaire, à la résolution la plus fine soit 10m. Les bandes 1 (Coastal aérosol) et 9 (vapeur d'eau) à une résolution de 60m ont été laissée de côté en raison de leur faible intérêt dans le contexte d'étude et de leur résolution, trop large, pour l'objectif poursuivi ici.

Les bandes du rouge, vert, bleu et infrarouge (R, G, B et IR) des images Pléiades ont une résolution spatiale initiale de 2 mètres, mais ont été rééchantillonnées à 0,5m par pansharpening à partir de la bande panchromatique.

**Figure 4 : Caractéristiques des bandes Sentinel-2 et Pléiades**

Domaine spectral	Sentinel-2			Pléiades		
	Bande	Longueur d'onde (nm)	Résolution spatiale (m)	Bande	Longueur d'onde (nm)	Résolution spatiale (m)
Bleu	B2	448-546	10	B1	430-550	2
Vert	B3	537-582	10	B2	490-610	2
Rouge	B4	645-713	10	B3	600-720	2
Vegetation Red Edge	B5	694-713	20	-		
	B6	731-749	20			
	B7	768-796	20			
	B8A	848-881	20			
Proche infrarouge (NIR)	B8	763-908	10	B4	750-950	2
Visible	-	-	-	P	450-800	0.5
Infra-rouge à ondes courtes (SWIR)	B11	1542-1757	20	-		
	B12	2081-2323	20			

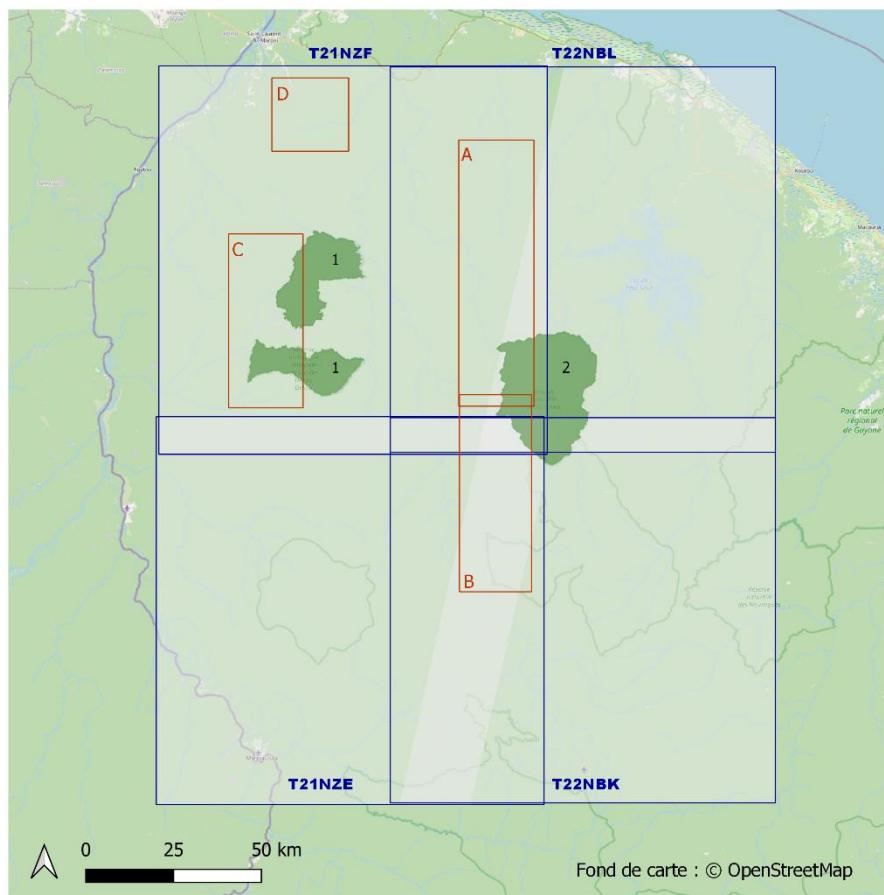
L'objectif premier étant ici de produire une cartographie précise des déperissements observés à partir de mai 2022, les images utilisées pour calibrer le modèle ont été celles acquises en 2023. Pour cette année, davantage de données très haute résolution Pléiades, permettant la constitution d'un jeu de donnée, étaient disponibles (Cf. Figure 5). De plus, c'est sur les images de cette année que le phénomène de déperissement est plus visible. Le modèle entraîné sur 2023 a ensuite été utilisé pour produire une classification pour 2020 et 2024. Les déperissements survenus aux abords de la Réserve Nationale (RNN) de la Trinité et de la Réserve Biologique Intégrale (RBI)

de Lucifer/Dékou-Dékou regroupant notamment des groupements végétaux patrimoniaux ont été ciblées pour être les zones à cartographier en priorité en raison des forts enjeux qu'ils soulèvent. Ainsi, l'acquisition d'images Pléiades a d'abord été commandée dans ces zones. La tuile Sentinel-2 T21NZF, se superposant avec la plupart des images Pléiades disponibles (Cf. Figure 5) et avec les zones d'intérêt, a été retenue pour l'entraînement du RF. Les tuiles permettant de recouvrir intégralement la RNN de la Trinité ont ensuite fait l'objet d'une classification à partir du RF entraîné sur la T21NZF.

**Figure 5 : Localisation et dates d'acquisition des images Pléiades et Sentinel-2 utilisées**

<span style="border: 1px solid orange; padding: 2px;"> </span>	Emprises des acquisitions Pléiades
<span style="border: 1px solid blue; padding: 2px;"> </span>	Tuiles Sentinel-2
<span style="background-color: #e0e0e0; border: 1px solid black; padding: 2px;"> </span>	Zones d'acquisition Sentinel-2
<span style="background-color: #6aa84f; border: 1px solid black; padding: 2px;"> </span>	RBI Lucifer/Dékou-Dékou (1) et RNN la Trinité (2)

Pléiades	
A	21/09/2023
B	08/09/2023
C	09/10/2023
D	23/07/2024
Sentinel-2	
T21NZF	16/10/2020 06/09/2023 28/02/2024
T22NBL	13/09/2020 08/10/2023 29/06/2024
T21NZE	16/10/2020 06/09/2023 28/02/2024
T22NBK	23/10/2020 08/10/2023 29/06/2024



## Méthodologie

Plusieurs étapes sont nécessaires à l'établissement d'une cartographie des zones dépréssantes à partir de l'imagerie Sentinel-2. Dans un premier temps, différents indices de végétation ont été sélectionnés et calculés dans l'objectif d'enrichir l'information spectrale contenue dans les images Sentinel-2. Les indices retenus ici sont recensés dans le tableau ci-dessus (Cf. Figure 3).

Il a semblé pertinent de simplifier l'information contenue dans les images en masquant, dans un premier temps, les nuages et les ombres et, dans un second temps, le reste des objets ne correspondant pas à la forêt. En effet, cette étape du traitement

permet de limiter la quantité de données à analyser pour la classification des dépérissements et peut permettre d'améliorer la précision, de réduire le bruit dans le résultat obtenu et de sélectionner les variables les plus pertinentes pour l'objectif spécifique. Pour ce faire, une même méthodologie utilisant l'algorithme RF a été appliquée, méthode décrite ci-dessous qui a ensuite été utilisée pour classifier les zones de forêt.

La constitution du jeu de données a été réalisée par photo-interprétation sur des zones délimitées, situées dans l'emprise de la tuile Sentinel-2 T21NZF depuis des compositions colorées vraies couleurs à partir des images Sentinel-2 pour le masque nuages et le masque forêt tandis qu'elle s'est basée sur des compositions colorées vraies et fausse couleurs issues des images Pléiades pour la classification des dépérissements.

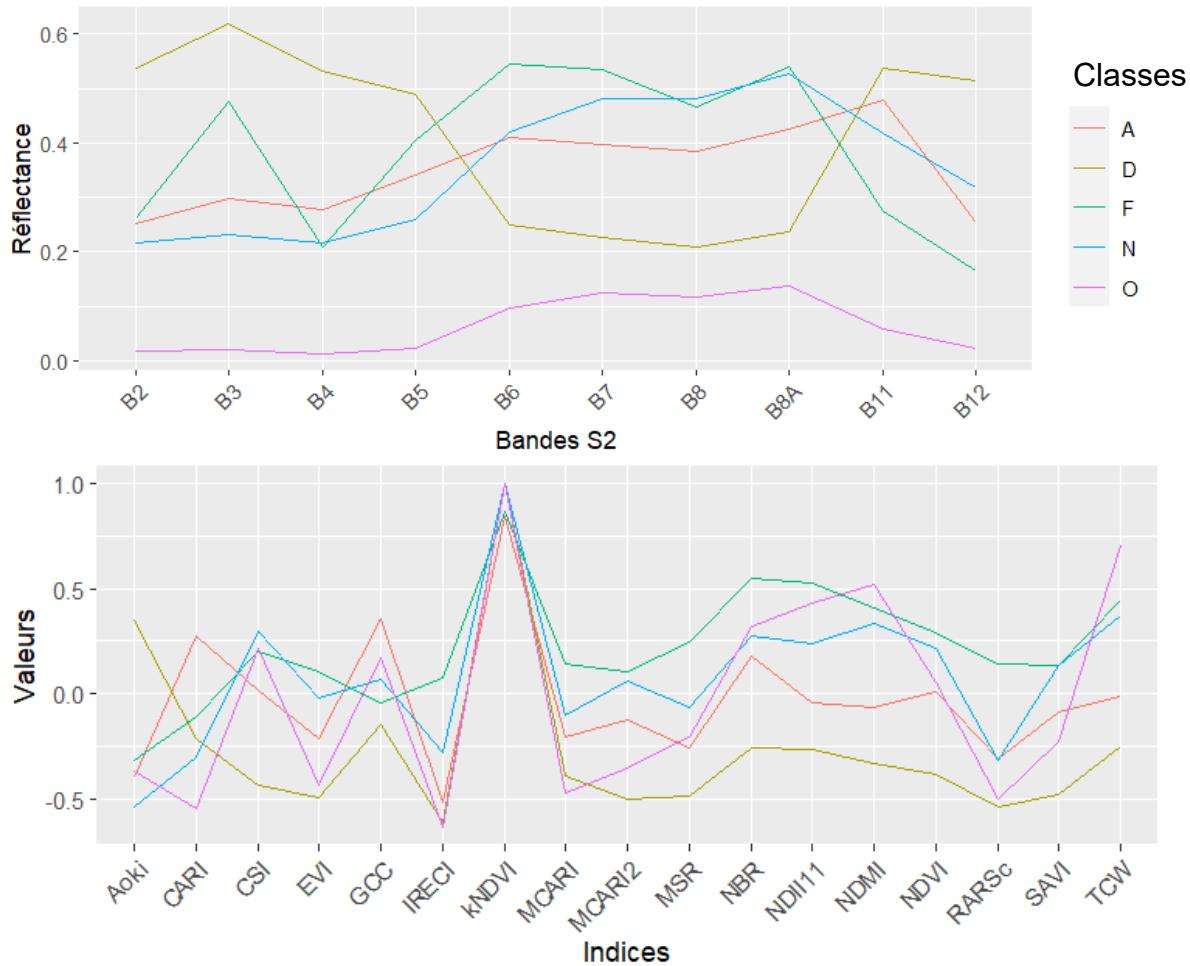
#### *Description de la démarche pour la photo-interprétation des dépérissements*

Les groupes de pixels de couleur brun/rosé sur la composition colorée vraie couleur ont été classés comme dépérissements. En cas de doute, l'observation sur la composition colorée fausse couleur (R : Vert, G : Rouge, B : IR) d'une teinte jaune-marron pour ces mêmes pixels confirmait l'attribution du groupe de pixel (sous forme de polygone) à la classe dépérissements. Les polygones de la classe forêt (soit forêt saine) sont tous des cercles de rayon 20m, après plusieurs essais, une partie d'entre eux a été placée en cœur de zone saine et d'autre aux abords des zones dépérissantes pour moduler la sensibilité de l'algorithme. Ici, l'objectif était de réduire autant que possible les faux positifs, quitte à augmenter sensiblement la prévalence de faux négatifs.

La photo-interprétation a été effectuée tout en veillant à ce que les polygones générés aient des tailles relativement homogènes. Dans le cas où la classe avec les plus petits polygones présentait un nombre médian de pixels par polygone inférieur à 10, alors un échantillonnage aléatoire sans remise de n pixels par polygone a été mené. Le nombre n est choisi de manière à maximiser le coefficient Kappa, avec n le plus petit en cas d'*ex-æquo*. Lorsque le nombre médian de pixels par polygone est supérieur ou égal à 10, n est défini comme le nombre de pixels du plus petit polygone, et n pixels sont alors échantillonés par polygone. Seul le jeu de données destiné à la classification des dépérissements forestiers a fait l'objet d'une détermination de n au regard du coefficient Kappa, en effet les dépérissements sont la seule classe pour laquelle la médiane du nombre de pixels par polygones était inférieure à 10. Sans cela, pour atteindre un nombre de pixels échantillonés assez conséquent il aurait fallu augmenter massivement le nombre de polygones produits, leur taille étant limitée par l'étendue des dépérissements.

Les graphiques ci-dessous (Fig. 6) permettent d'observer les signatures spectrales des différents groupes de polygones générés pour la constitution des différents jeux de données.

**Figure 6 : Profils et indices spectraux des différents objets classifiés**



A : Autres modalités d'occupation du sol ; D : Dépérissements ; F : Forêt Saine ; N : Nuages, O : Ombres

On observe sur la figure 6 une forte réflectance des dépérissements dans le visible et dans l'infrarouge à ondes courtes (B11), et une plus faible réflectance dans le domaine du Red Edge (B6 et B8A), là où la forêt saine présente des valeurs de réflectance les plus fortes. Sans surprise, la classe comprenant les autres modalités d'occupation du sol présente des valeurs plutôt moyennes, cette classe présente aussi des écarts types plus importants du fait de la diversité des objets qu'elle peut comprendre (ex : routes, zones de culture, végétation basse, zones d'activité minière, etc.), ceci met en avant la nécessité d'utiliser un masque forêt performant pour faciliter la classification forêt saine/dépérissements.

Du côté des indices spectraux (Fig. 6) on peut noter que le NDII11 semble pouvoir permettre de distinguer la plupart des objets ciblés ici, dans une moindre mesure cette observation semble aussi pouvoir s'appliquer au MCARI2. Ces indices sont respectivement mis en avant pour la détection de défoliation légère et comme proxy du LAI.

Après l'échantillonnage, le jeu de données est divisé en un jeu de calibration (70%) et un jeu de validation (30%). Cette séparation est effectuée en veillant à ce que tous les pixels d'un même polygone soient attribués exclusivement à l'un des deux ensembles. Cette approche vise à limiter l'influence de l'autocorrélation spatiale dans l'entraînement du modèle RF tout en maximisant le nombre d'échantillons disponibles. Contrairement à une méthode où une seule valeur par polygone serait retenue, nous conservons n valeurs par polygone, multipliant ainsi par n le nombre d'échantillons.

Le modèle est ensuite entraîné en utilisant toutes les variables disponibles (10 bandes spectrales + 17 indices), et les variables classées par importance selon le score MDA (Mean Decrease Accuracy). Cette méthode évalue l'importance des variables en mesurant la diminution de la précision du modèle lorsque les valeurs d'une variable particulière sont permutées de manière aléatoire. L'algorithme est ensuite entraîné avec la plus importante puis en ajoutant à chaque itération la variable restante ayant la meilleure MDA, jusqu'à avoir utilisé la totalité des variables. Le meilleur ensemble de variables est sélectionné au regard du coefficient Kappa le plus élevé et du nombre de variable le plus faible en cas d'égalité.

**Figure 7 : Caractéristiques des différentes classifications par RF menées**

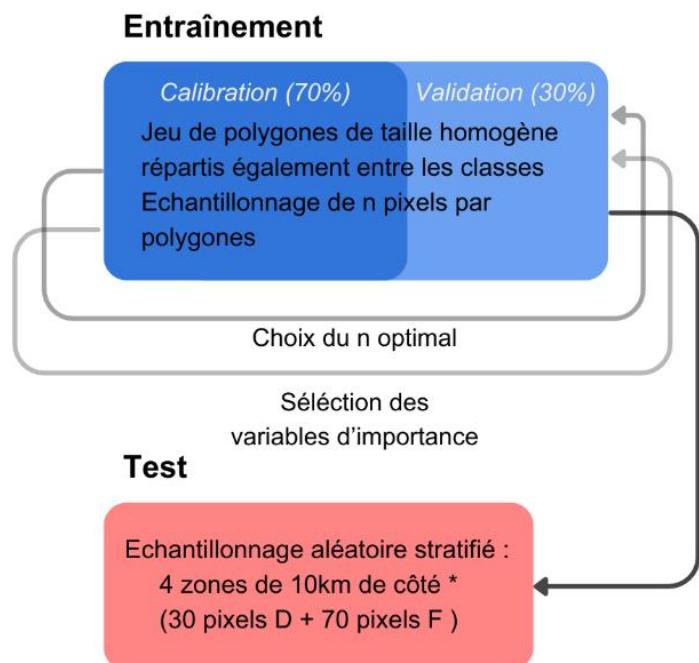
	Masque Nuages/Ombres	Masque Forêt	Classification déperissements
Nombre de polygones (retenus) par classe	O : 29 N : 29 A : 29	F : 18 A : 18	D : 211 F : 212
Zones échantillonnées	NW + Centre	NW + Ddkd	Trinite + Ddkd
Nombre de pixels échantillonnés par polygones retenus	113	43	11
Variables retenues	B2, NDII11, GCC NDMI, B3, B11, B5 B4, B8A, B12, Aoki, B8, RARSc, EVI, B7	B3, B5, B11, B12, B4, GCC	MSR, IRECI, RARSc, NBR, B12, B7, NDVI, B4, kNDVI, NDII11, B6, NDMI, B11, Aoki, TCW
Résultats de la validation	Kappa : 0,93 F1 score O : 0,95 N : 0,98 A : 0,93	Kappa : 0,98 F1 score F : 0,99 A : 0,99	Kappa : 0,93 F1 score D : 0,97 F : 0,97

Le masque nuages généré dans cette chaîne de traitement, a été soumis à un filtre morphologique en deux étapes : une érosion suivie d'une dilatation, appliquées à l'aide d'une fenêtre glissante de 5x5 pixels. L'objectif est de réduire le bruit et de s'assurer que les zones de transition entre les ombres et les nuages sont correctement masquées lorsque nécessaire. De manière similaire, les zones de forêt issues du masque forêt ont été érodées à l'aide d'une fenêtre glissante de 3x3 pixels, afin de limiter la détection de faux positifs à proximité des zones non forestières.

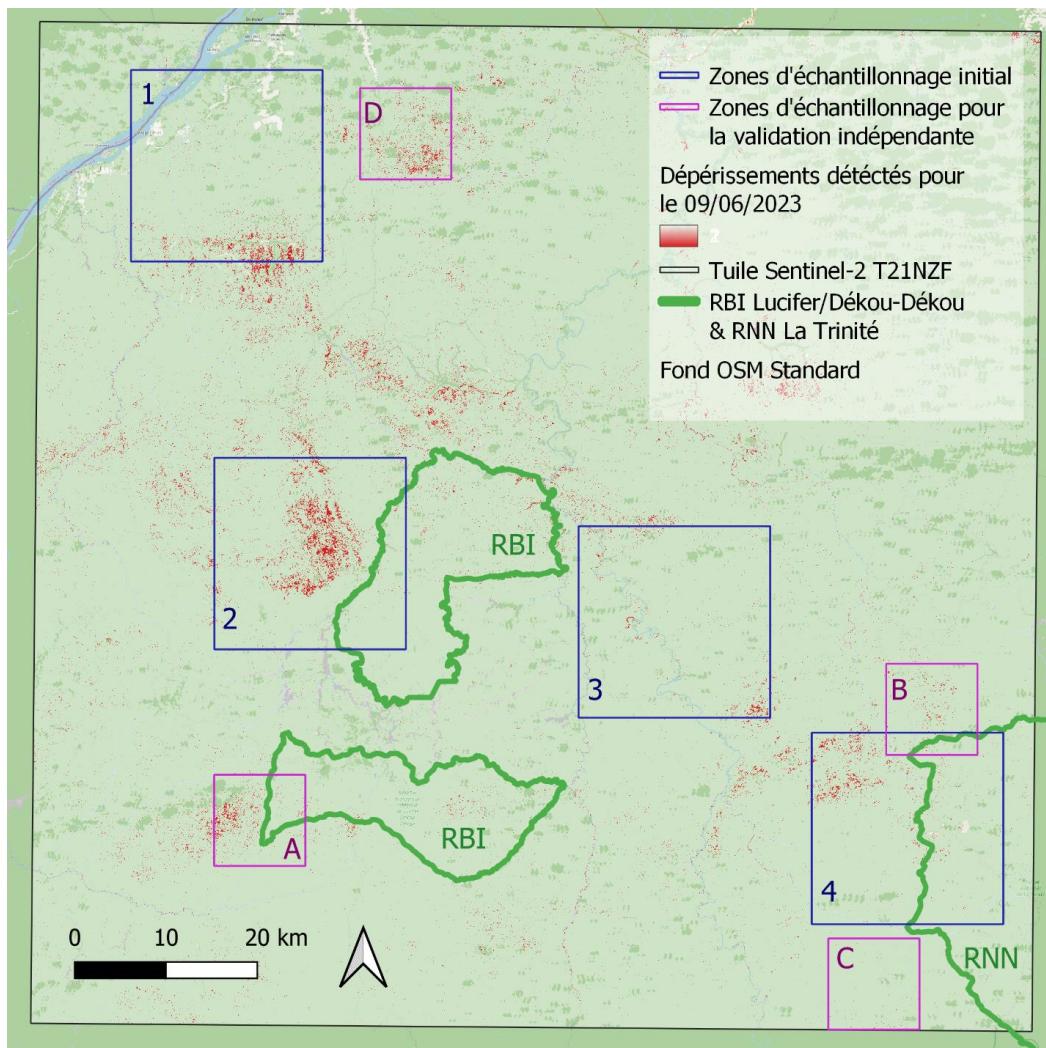
La classification entre forêt saine et dépérissements est ensuite réalisée à partir de la chaîne de traitement décrite plus haut à partir des images Sentinel-2. Les pixels correspondant à des nuages, des ombres ou à des zones d'occupation du sol non forestières sont systématiquement masqués pour améliorer la précision du résultat.

**Figure 8 : Synthèse de la méthode de validation utilisée pour la classification des dépérissements**

Pour vérifier la robustesse de la méthode utilisée et la qualité de la cartographie produite à partir de la classification par RF, une évaluation des résultats a été mise en place. Trois zones des 10\*10km<sup>2</sup>, distinctes des zones utilisées pour la constitution du jeu de données initial (Cf. Figure 8), ont été retenues pour procéder à cette évaluation pour les images de 2023 et une zone respectant les mêmes critères a été retenue pour 2024.



**Figure 9 : Carte de localisation des zones échantillonnage pour l'entraînement et le test du RF pour la classification des zones de dépréisements forestiers**



#### Dénomination des zones d'échantillonnage

1 : Nord-Ouest (NW)	A : RBI Lucifer/Dékou-Dékou (Ddkd 2)
2 : RBI Lucifer/Dékou-Dékou (Ddkd)	B : RNN la Trinité (Trinité 1)
3 : Centre	C : RNN la Trinité (Trinité 2)
4 : RNN la Trinité (Trinité)	D : Crique Saut Portal (Portal)

Les zones retenues pour 2023 comportent des taux de dépréisements détectés faibles, moyen et fort et se situent à proximité des zones utilisée pour l'échantillonnage initial. Tandis que la zone retenue pour 2024 comporte un taux de dépréissement plutôt fort et se situe dans une zone pour laquelle aucune image pléiades n'était disponible en 2023 et qui se trouve à distance des zones utilisée pour la calibration du modèle.

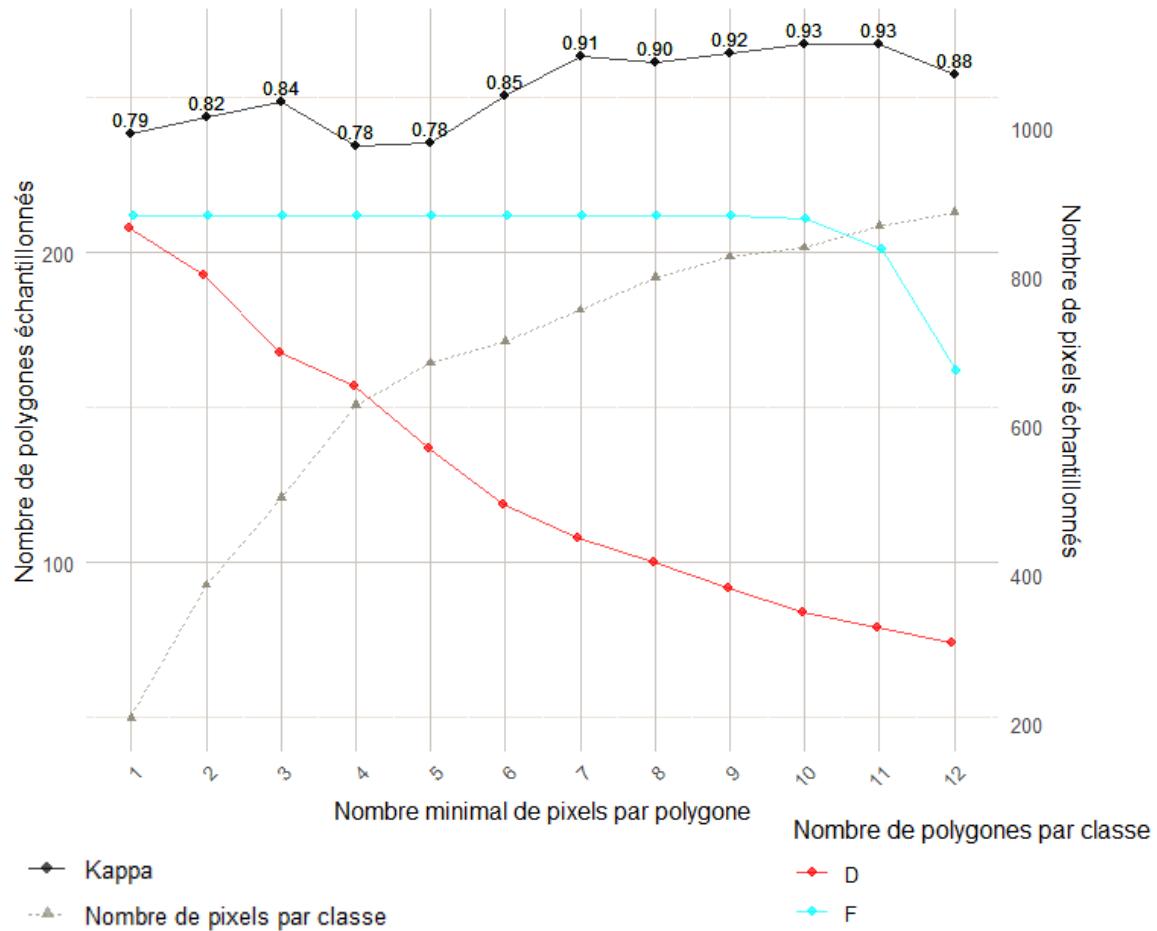
Les ombres, nuages et occupations du sols ne correspondant pas à des zones forestières sur les images S2 ont encore une fois été exclues. L'objectif étant de comparer les résultats de la classification à partir de S2 aux images pléiades, les nuages et les ombres présents sur les images pléiades ont également été exclus pour cette opération.

Dans un premier temps, l'échantillonnage par hyper cube latin a été envisagé mais n'a pas semblé adapté au problème posé ici. En effet, l'échantillon issu de cette méthode comportait un faible nombre de zones dépréssantes et une forte quantité de zones de transition entre forêt saine et dépréssements. Cette méthode a donc été mise de côté pour privilégier un échantillonnage aléatoire stratifié, plus adapté ici. Ainsi, dans chaque zone de  $10*10\text{km}^2$ , 30 points correspondants à des dépréssements dans la cartographie produite et 70 points correspondants à des zones de forêt saine ont été échantillonné aléatoirement. En effet, la surface de dépréissement représentant une faible portion de l'espace, l'échantillonnage égale pour les deux classes aurait mené à l'échantillonnage de pixels très proches donc très similaires dans la classe dépréissement. Du même temps, la classe forêt saine étant beaucoup plus représentée dans ces espaces, un échantillonnage plus important sur ces zones semble favoriser la détection de faux négatifs.

## Résultats

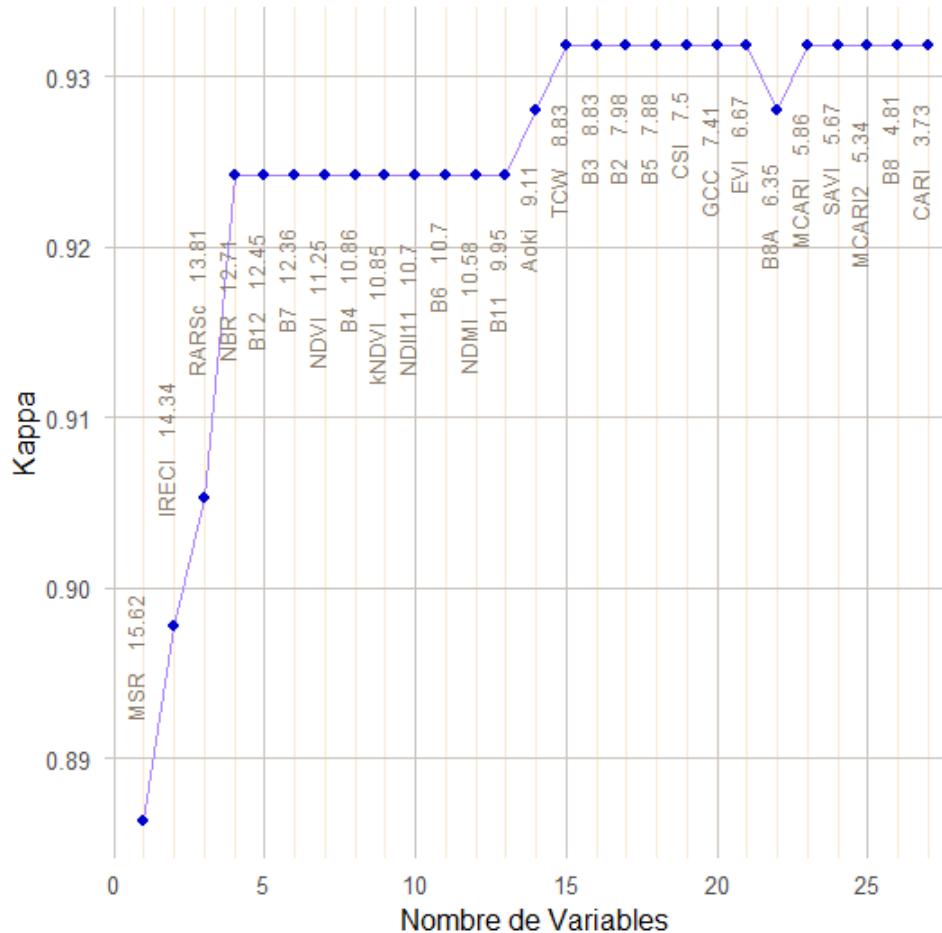
En ce qui concerne  $n$ , soit le nombre de pixels à échantillonner par polygones pour mettre en forme le jeu de données utilisé pour la classification des dépréssements par RF, la valeur retenue ici est  $n = 11$  car elle permet d'obtenir le meilleur Kappa. La figure 10 laisse à penser que cette valeur correspond à un compromis entre un nombre de pixel échantillonné important et un nombre de polygones échantillonné élevé (ce qui assure une plus grande diversité des valeurs). En effet, on constate que le Kappa diminue après avoir atteint 0.9318 (Kappa = 0.9308 pour  $n = 10$ ) et l'on suppose que cette baisse est due à une réduction importante du nombre de polygones échantillonnés dans la classe forêt. En effet ces polygones font tous la même taille à l'origine et comportent sensiblement le même nombre de pixels (à l'exception de ceux avec des pixels masqués, ce qui explique la légère baisse de polygones échantillonnables pour cette classe entre  $n = 10$  et  $n = 11$ ). Cette réduction drastique réduirait aussi fortement la variabilité des pixels forêts utilisés dans le jeu d'entraînement alors que la forêt est une classe assez variable. L'impact moins fort de la réduction du nombre de polygones échantillonnables dans la classe dépréssements sur la valeur du kappa semble être due au fait que le facteur limitant pour cette classe pourrait davantage être le nombre de pixels échantillonnés. Pour vérifier ces hypothèses il pourrait être pertinent de comparer les variabilités inter-pixels et inter-polygones de chaque classe.

**Figure 10 : Evolution du Kappa en fonction du nombre de pixels échantillonnés par polygones pour la classification des zones de dépérissements forestiers**



Les bandes et indices retenus pour la classification des dépérissements sont les suivants : MSR, IRECI, RARSc, NBR, B12, B7, NDVI, B4, kNDVI, NDII11, B6, NDMI, B11, Aoki, TCW. Les indices et bandes retenus pour cette classification (Cf. Figure 11) sont associés à la détection de la défoliation, du stress hydrique et du déclin de la végétation, souvent observés en période de sécheresse. Les bandes B11 et B12, sensibles à la teneur en eau des plantes, jouent un rôle crucial pour identifier les zones affectées par un stress sévère. La combinaison de ces variables permet une évaluation précise de la santé de la canopée. Sur la figure ci-dessous on observe des zones de plateau, qui laissent penser à une forte redondance entre les variables utilisées, ainsi on peut supposer qu'il est possible de réduire encore le nombre de variables utilisées dans le RF sans pour autant réduire significativement la qualité de la classification.

**Figure 11 : Evolution du Kappa en fonction des variables sélectionnées pour la classification des zones de déprérissement forestier**



La carte ci-dessous (Fig. 12) représente le résultat de la classification pour la tuile Sentinel T21NZF du 6 septembre 2023. Cette zone, centrée sur le quart Nord-Ouest de la Guyane Française, montre une prévalence plus élevée des déprérissements dans l'Ouest.

Les résultats mettent en avant l'apparition des déprérissements forestiers entre 2020 et 2023 dans toutes les zones étudiées, suivie d'une légère diminution en 2024, sans toutefois revenir aux niveaux observés en 2020. La RBI Lucifer/Dékou-Dékou semble particulièrement vulnérable par rapport à la RNN de la Trinité, où les déprérissements sont moindres. En effet, on observe respectivement pour ces zones 0,67 % de déprérissements pour la RBI Lucifer/Dékou-Dékou contre 0,33 % pour la RNN de la Trinité en 2023.

Figure 12 : Carte des dépérissements détectés pour la tuile S2 T21NZF le 06/09/2023

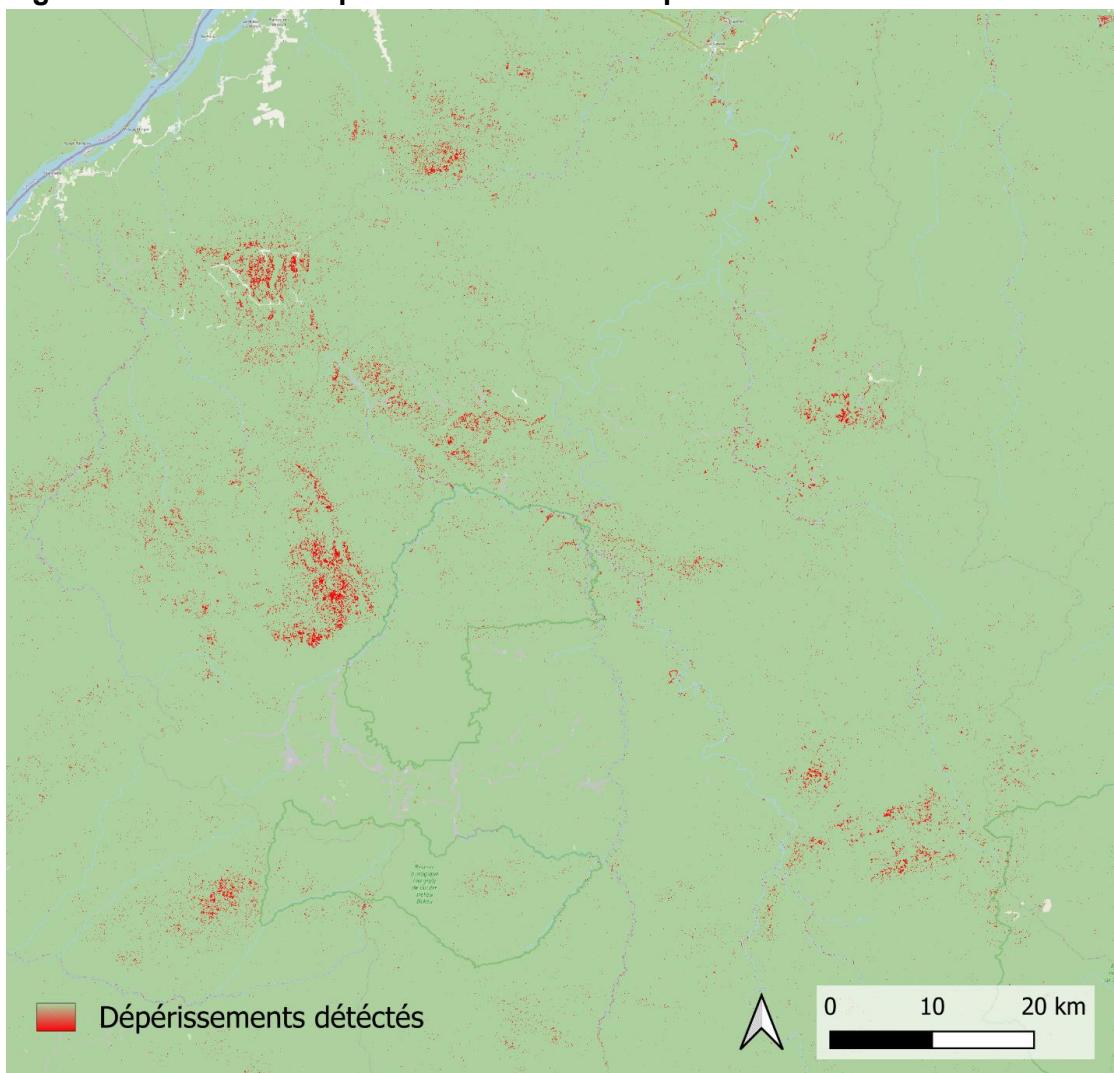
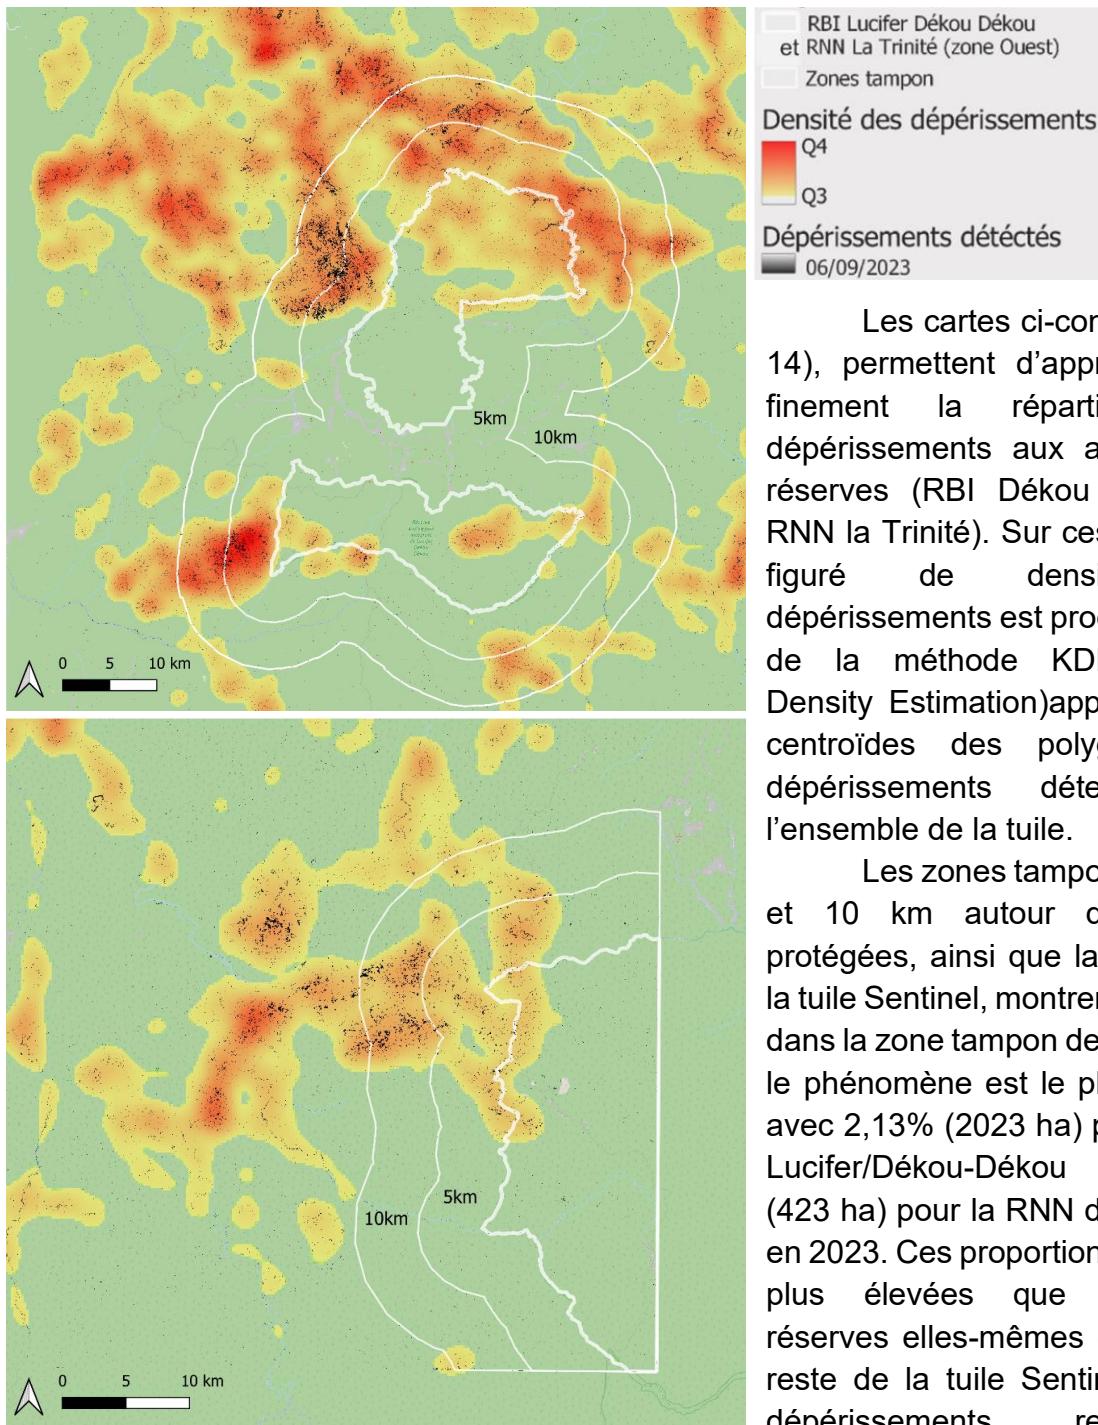


Figure 13 : Superficie des dépérissements détectés à partir de la tuile S2 T21NZF

\*les valeurs en % sont données en référence à la superficie non masquée de la zone concernée

Année unité	2020		2023		2024	
	ha	%	ha	%	ha	%
<b>RBI Lucifer/Dékou-Dékou</b>	7	0.01	401	0.67	237	0.41
<b>RBI Lucifer/Dékou-Dékou ZT 5km</b>	19	0.02	1665	1.75	904	0.99
<b>RBI Lucifer/Dékou-Dékou ZT 10km</b>	24	0.02	2023	2.13	1215	1.36
<b>RNN la Trinite</b>	27	0.10	106	0.33	72	0.40
<b>RNN la Trinite ZT 5km</b>	10	0.04	244	0.88	155	0.70
<b>RNN la Trinite ZT 10km</b>	10	0.03	423	1.42	416	1.51
<b>T21NZF</b>	293	0.03	12411	1.13	8013	0.85

**Figure 14 : Carte des dépréisements détectés aux abords des réserves à partir de la tuile S2T21NZF le 06/09/2023**



Les cartes ci-contre (Figure 14), permettent d'apprécier plus finement la répartition des dépréisements aux abords des réserves (RBI Dékou Dékou et RNN la Trinité). Sur ces cartes, le figuré de densité des dépréisements est produit à partir de la méthode KDE (Kernel Density Estimation) appliquée aux centroïdes des polygones de dépréisements détectés sur l'ensemble de la tuile.

Les zones tampons de 5 km et 10 km autour des zones protégées, ainsi que la totalité de la tuile Sentinel, montrent que c'est dans la zone tampon de 10 km que le phénomène est le plus sévère, avec 2,13% (2023 ha) pour la RBI Lucifer/Dékou-Dékou et 1,42% (423 ha) pour la RNN de la Trinité en 2023. Ces proportions sont bien plus élevées que dans les réserves elles-mêmes ou dans le reste de la tuile Sentinel, où les dépréisements représentent 1,13% soit 12 411 ha.

Les résultats de la validation et de l'évaluation effectuées montrent une bonne concordance entre les jeux de données utilisés et la classification obtenue par RF (voir figure ci-dessous). Toutefois, une diminution significative du coefficient de Kappa est

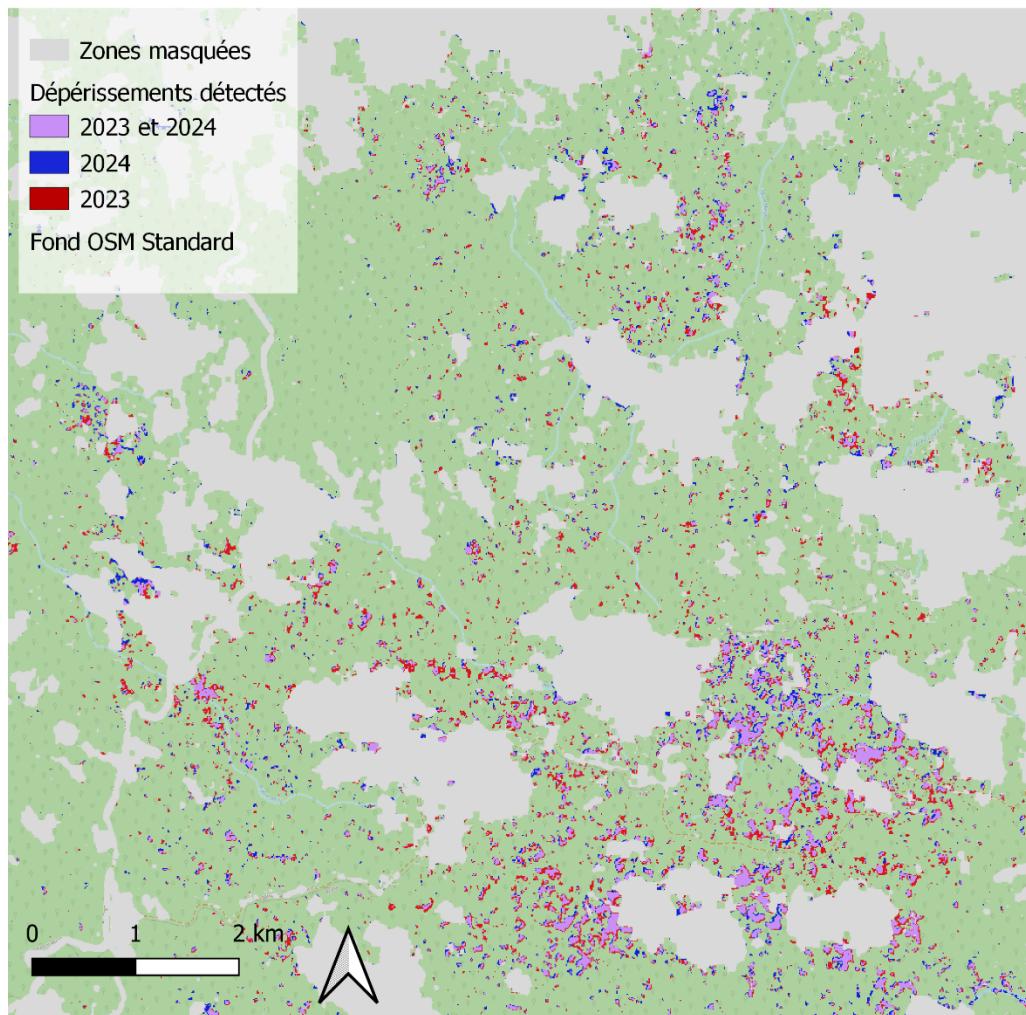
observée entre la validation (0,93) et l'évaluation (0,74). Elle pourrait être attribuée à un surapprentissage du modèle pour les zones échantillonnées initialement et/ou aux différences entre les jeux de données, notamment en ce qui concerne la méthode d'échantillonnage.

En effet, les polygones utilisés pour entraîner le modèle ont été sélectionnés afin de favoriser une cartographie précise des dépérissements, avec une approche plus restrictive pour la classification de ces derniers. Car, en réalité, bien qu'il existe des zones nettement dépérisantes et d'autres clairement saines, il existe également un continuum de valeurs spectrales entre ces deux états, reflétant souvent une transition progressive. Ainsi, lors de la constitution du jeu de données initial, les polygones correspondant aux zones de dépérissement ont été placés dans des zones présentant un dépérissement franc, tandis que ceux correspondant aux forêts saines ont été positionnés à la fois au cœur des zones forestières et à proximité des zones dépérisantes. Cela a permis d'éviter une surreprésentation des zones de dépérissement dans la classification finale.

En revanche, le jeu de données utilisé pour l'évaluation a été généré aléatoirement à partir des résultats de la classification, incluant parfois des zones plus difficiles à interpréter visuellement. Ce qui peut expliquer que les zones de dépérissement affichent le F1-score le plus faible lors de l'évaluation (0,81 contre 0,93 pour les zones de forêt saine). Cela peut révéler une prévalence plus élevée de faux négatifs que de faux positifs, ce qui répondrait à l'objectif initial de produire une cartographie recensant uniquement les zones de dépérissement franc.

	Kappa	F1 Scores	
		Forêt saine	Dépérissements
Validation	0.93	0.96	0.97
Evaluation	0.74	0.93	0.81

**Figure 15 : Carte de changement des dépérissements détectés sur la Crique Saut Portal (2023-2024)**



Enfin, ce travail a permis de mettre en évidence l'existence d'une zone significativement impactée par les dépérissements au niveau de Crique Portal. La disponibilité d'une image Pléiades sur cette zone en 2024 (février) a permis d'envisager une évaluation des résultats de la classification pour une zone et une date n'ayant pas été utilisées dans la construction du jeu de données initial. Cependant, la photo-interprétation des zones de dépérissements à partir des images Pléiades, nécessaires à cette démarche n'a pas été possible. En effet, les zones touchées par les dépérissements présentaient des valeurs spectrales trop proches de celles des zones de forêt saine pour les quelques bandes disponibles pour les images Pléiades. Ce qui pourrait être dû à une reprise de la végétation (probablement lianes et végétation basse/pionnière) entre septembre 2023 et février 2024 liée à l'ouverture de la canopée dans les zones dépérisantes. Cependant, l'utilisation du RF entraîné sur les données de 2023 permet une classification pour 2024 qui semble plutôt cohérente avec les zones touchées en

2024 et qui ne semble pas mettre en avant de nouvelles zones touchées. On peut donc supposer une relative robustesse du RF entraîné pour la classification des dépérissements et ce même après la reprise de la végétation grâce à la richesse de l'information spectrale contenue dans les bandes S2 sans pouvoir pour le moment valider cette hypothèse.

## Discussion

La télédétection s'est révélée être un outil efficace pour surveiller les dépérissements forestiers observés en Guyane Française en 2022. Grâce à l'utilisation combinée des données de résolution moyenne (Sentinel-2) et très haute résolution (Pléiades), une cartographie détaillée des dépérissements a pu être réalisée sur la tuile Sentinel-2 T21NZF, pour l'année 2023, permettant une détection plus précise du phénomène. L'analyse a confirmé que les dépérissements se situent principalement hors des réserves naturelles, bien que proches de sites protégés tels que la Réserve Biologique de Lucifer-Dékou-Dékou et la Réserve de la Trinité. Cette observation pourrait alerter sur la vulnérabilité accrue de ces zones, même en périphérie des espaces protégés.

L'utilisation de masques produit par RF a permis de limiter les biais lors des classifications, mais des améliorations pourraient encore être apportées. L'adoption d'une validation par k-fold semble être une piste prometteuse pour maximiser l'information extraite des échantillons initiaux, renforçant ainsi la robustesse des résultats. En effet, l'algorithme de classification Random Forest a atteint un Kappa de 0,93 lors de la validation, indiquant une concordance satisfaisante. Cependant, des divergences ont été relevées lors de l'évaluation avec un Kappa de 0,74, ce qui souligne la nécessité de continuer à ajuster le modèle.

Une autre difficulté est apparue dans la distinction des zones de défoliation face à la reprise de la végétation, surtout sur les images Pléiades récentes de 2024. Cette régénération rapide complexifie la classification RF, et il serait pertinent d'évaluer l'impact exact de cette dynamique sur la qualité des résultats. D'autre part, les bandes B11 et B12, sensibles à l'humidité, ainsi que les indices NDII11, NDMI, et MSR se sont avérés cruciaux pour la détection du stress hydrique et de la défoliation. Ces résultats renforcent l'hypothèse selon laquelle la sécheresse et les perturbations climatiques jouent un rôle clé dans les dépérissements forestiers observés.

Il a été envisagé de produire une classification sur les tuiles S2 adjacente mais cela n'a pas été possible. Il semblerait que les tuiles concernées présentent un décalage dans les valeurs spectrales qui soit trop important pour pouvoir mener à bien la classification à partir du RF entraîné sur la tuile S2 T21NZF. Une exploration plus approfondie des causes des erreurs, ainsi qu'un élargissement du jeu de données et l'ajout de la variable "tuile", pourraient réduire ces biais.

Enfin, l'application de techniques d'apprentissage automatique avancées, telles que les réseaux neuronaux convolutifs (CNN), pourrait constituer une avancée majeure pour affiner les résultats. De même que l'utilisation d'algorithme de détection de changement dans les séries temporelles. Ces approches permettraient de mieux saisir les variations subtiles de la végétation et de développer des modèles encore plus précis pour la détection des dépérissements.

Dans l'ensemble, ce travail pose les bases pour une meilleure compréhension des causes des dépérissements et fournit des informations clés pour l'élaboration de stratégies adaptées à la gestion des zones impactées ou à risque. Des efforts supplémentaires dans l'amélioration des méthodes de télédétection et des algorithmes de classification contribueront à une surveillance plus précise et à une prise de décision mieux informée dans les années à venir.

## References

- Akashi, Y. and Mueller-Dombois, D. (1995) 'A landscape perspective of the Hawaiian rain forest dieback', *Journal of Vegetation Science*, 6(4), pp. 449–464. Available at: <https://doi.org/10.2307/3236343>.
- Allen, K. et al. (2017) 'Will seasonally dry tropical forests be sensitive or resistant to future changes in rainfall regimes?', *Environmental Research Letters*, 12(2), p. 023001. Available at: <https://doi.org/10.1088/1748-9326/aa5968>.
- Berveglieri, A. et al. (2021) 'Analysis of trends and changes in the successional trajectories of tropical forest using the Landsat NDVI time series', *Remote Sensing Applications: Society and Environment*, 24, p. 100622. Available at: <https://doi.org/10.1016/j.rsase.2021.100622>.
- Bhattarai, R. et al. (2020) 'Sentinel-2 based prediction of spruce budworm defoliation using red-edge spectral vegetation indices', *Remote Sensing Letters*, 11(8), pp. 777–786. Available at: <https://doi.org/10.1080/2150704X.2020.1767824>.
- Bright, B.C. et al. (2014) 'Landsat Time Series and Lidar as Predictors of Live and Dead Basal Area Across Five Bark Beetle-Affected Forests', *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(8), pp. 3440–3452. Available at: <https://doi.org/10.1109/JSTARS.2014.2346955>.
- Camps-Valls, G. et al. (2021) 'A unified vegetation index for quantifying the terrestrial biosphere', *Science Advances*, 7(9), p. eabc7447. Available at: <https://doi.org/10.1126/sciadv.abc7447>.
- Cavender-Bares, J., Gamon, J.A. and Townsend, P. (2020) *Remote Sensing of Plant Biodiversity* | SpringerLink. Available at: <https://link.springer.com/book/10.1007/978-3-030-33157-3> (Accessed: 2 May 2024).
- Costa, F.R.C. et al. (2023) 'The other side of tropical forest drought: do shallow water table regions of Amazonia act as large-scale hydrological refugia from drought?', *New Phytologist*, 237(3), pp. 714–733. Available at: <https://doi.org/10.1111/nph.17914>.
- Delatour, C. (1990) 'Dépérississement des chênes et pathogènes', *Revue forestière française*, 42(2), pp. 182–185. Available at: <https://doi.org/10.4267/2042/26059>.
- Dezzeo, N., Hernández, L. and Fölster, H. (1997) 'Canopy dieback in lower montane forests of Alto Urimán, Venezuelan Guayana', *Plant Ecology*, 132(2), pp. 197–209. Available at: <https://doi.org/10.1023/A:1009719805461>.
- Dobrinić, D., Gašparović, M. and Medak, D. (2022) 'Evaluation of feature selection methodes for vegetation mapping using multitemporal Sentinel 2 imagery', *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLIII-B3-2022, pp. 485–491. Available at: <https://doi.org/10.5194/isprs-archives-XLIII-B3-2022-485-2022>.

van Emmerik, T. *et al.* (2017) 'Water stress detection in the Amazon using radar', *Geophysical Research Letters*, 44. Available at: <https://doi.org/10.1002/2017gl073747>.

EVI (Enhanced Vegetation Index) | *Sentinel Hub custom scripts* (no date). Available at: <https://custom-scripts.sentinel-hub.com/custom-scripts/sentinel-2/evi/> (Accessed: 12 August 2024).

Flores, B.M., Montoya, E. and Sakschewski, B. (2024) *Critical transitions in the Amazon forest system* | *Nature*. Available at: <https://www.nature.com/articles/s41586-023-06970-0> (Accessed: 29 April 2024).

Fremout, T. *et al.* (2022) 'Site-specific scaling of remote sensing-based estimates of woody cover and aboveground biomass for mapping long-term tropical dry forest degradation status', *Remote Sensing of Environment*, 276, p. 113040. Available at: <https://doi.org/10.1016/j.rse.2022.113040>.

Garrity, S.R. *et al.* (2013) 'Quantifying tree mortality in a mixed species woodland using multitemporal high spatial resolution satellite imagery', *Remote Sensing of Environment*, 129, pp. 54–65. Available at: <https://doi.org/10.1016/j.rse.2012.10.029>.

Gonçalves, N.B. *et al.* (2020) 'Both near-surface and satellite remote sensing confirm drought legacy effect on tropical forest leaf phenology after 2015/2016 ENSO drought', *Remote Sensing of Environment*, 237, p. 111489. Available at: <https://doi.org/10.1016/j.rse.2019.111489>.

Huang, W. *et al.* (2018) 'Monitoring Crop Carotenoids Concentration by Remote Sensing', in *Progress in Carotenoid Research*. IntechOpen. Available at: <https://doi.org/10.5772/intechopen.78239>.

Huete, A. *et al.* (2002) 'Overview of the radiometric and biophysical performance of the MODIS vegetation indices', *Remote Sensing of Environment*, 83(1), pp. 195–213. Available at: [https://doi.org/10.1016/S0034-4257\(02\)00096-2](https://doi.org/10.1016/S0034-4257(02)00096-2).

Jump, A.S. *et al.* (2017) 'Structural overshoot of tree growth with climate variability and the global spectrum of drought-induced forest dieback', *Global Change Biology*, 23(9), pp. 3742–3757. Available at: <https://doi.org/10.1111/gcb.13636>.

Landmann, G. (1994) 'Concepts, définitions et caractéristiques générales des déprésissements forestiers', *Revue forestière française*, 46(5), pp. 405–415. Available at: <https://doi.org/10.4267/2042/26563>.

Laurance, S.G.W. *et al.* (2009) 'Long-term variation in Amazon forest dynamics', *Journal of Vegetation Science*, 20(2), pp. 323–333. Available at: <https://doi.org/10.1111/j.1654-1103.2009.01044.x>.

Lausch, A. *et al.* (2016) 'Understanding Forest Health with Remote Sensing -Part I—A Review of Spectral Traits, Processes and Remote-Sensing Characteristics', *Remote Sensing*, 8(12), p. 1029. Available at: <https://doi.org/10.3390/rs8121029>.

Losso, Adriano *et al.* (2022) 'Canopy dieback and recovery in Australian native forests following extreme drought | *Scientific Reports*'. Available at: <https://www.nature.com/articles/s41598-022-24833-y> (Accessed: 7 June 2024).

Mattos, C.R.C. *et al.* (2023) 'Double stress of waterlogging and drought drives forest–savanna coexistence', *Proceedings of the National Academy of Sciences*, 120(33), p. e2301255120. Available at: <https://doi.org/10.1073/pnas.2301255120>.

McDowell, N., Allen, C. and Anderson-Texeira, K. (2018) *Drivers and mechanisms of tree mortality in moist tropical forests - McDowell - 2018 - New Phytologist - Wiley Online Library*. Available at: <https://nph.onlinelibrary.wiley.com/doi/10.1111/nph.15027> (Accessed: 30 April 2024).

Moreno-Fernández, D. *et al.* (2021) 'Using spectral indices as early warning signals of forest dieback: The case of drought-prone *Pinus pinaster* forests', *Science of The Total Environment*, 793, p. 148578. Available at: <https://doi.org/10.1016/j.scitotenv.2021.148578>.

Mueller-Dombois, D. (1986) 'Perspectives for an Etiology of Stand-Level Dieback', *Annual Review of Ecology Evolution and Systematics*, 17, pp. 221–243. Available at: <https://doi.org/10.1146/annurev.es.17.110186.001253>.

Nagai, S., Ichii, K. and Morimoto, H. (2007) 'Interannual variations in vegetation activities and climate variability caused by ENSO in tropical rainforests', *International Journal of Remote Sensing*, 28(6), pp. 1285–1297. Available at: <https://doi.org/10.1080/01431160600904972>.

ONF (2023) *Déperissement forestier: quand les arbres tombent malades*, Office national des forêts. Available at: <https://www.onf.fr/onf/+/7e6::deperissement-forestier-quand-les-arbres-tombent-malades.html> (Accessed: 6 May 2024).

Pau, S., Okin, G. and Gillespie, T. (2010) 'Asynchronous Response of Tropical Forest Leaf Phenology to Seasonal and El Nino-Driven Drought', *PLoS one*, 5, p. e11325. Available at: <https://doi.org/10.1371/journal.pone.0011325>.

Pause, M. *et al.* (2016) 'In Situ/Remote Sensing Integration to Assess Forest Health—A Review', *Remote Sensing*, 8(6), p. 471. Available at: <https://doi.org/10.3390/rs8060471>.

Pontius, J. (2014) 'A new approach for forest decline assessments: Maximizing detail and accuracy with multispectral imagery', *International Journal of Remote Sensing*, 35. Available at: <https://doi.org/10.1080/01431161.2014.903439>.

Rammig, A. *et al.* (2010) 'Estimating the risk of Amazonian forest dieback', *New Phytologist*, 187(3), pp. 694–706. Available at: <https://doi.org/10.1111/j.1469-8137.2010.03318.x>.

Saatchi, S. *et al.* (2013) 'Persistent effects of a severe drought on Amazonian forest canopy', *Proceedings of the National Academy of Sciences*, 110(2), pp. 565–570. Available at: <https://doi.org/10.1073/pnas.1204651110>.

Scheel, H.J. (2018) 'Experiences from the Fukushima Disaster', in *Environmental Risks*. IntechOpen. Available at: <https://doi.org/10.5772/intechopen.77726>.

Sinergise, S.-H. by (no date) MCARI (*Modified Chlorophyll Absorption in Reflectance Index*), *Sentinel Hub custom scripts*. Available at: <https://custom->

<scripts.sentinel-hub.com/custom-scripts/sentinel-2/mcari/> (Accessed: 23 September 2024).

Spruce, J.P. *et al.* (2011) 'Assessment of MODIS NDVI time series data products for detecting forest defoliation by gypsy moth outbreaks', *Remote Sensing of Environment*, 115(2), pp. 427–437. Available at: <https://doi.org/10.1016/j.rse.2010.09.013>.

Staal, A. *et al.* (2016) 'Bistability, Spatial Interaction, and the Distribution of Tropical Forests and Savannas', *Ecosystems*, 19(6), pp. 1080–1091. Available at: <https://doi.org/10.1007/s10021-016-0011-1>.

Torres, P. *et al.* (2021) 'The Role of Remote Sensing for the Assessment and Monitoring of Forest Health: A Systematic Evidence Synthesis', *Forests*, 12(8), p. 1134. Available at: <https://doi.org/10.3390/f12081134>.

Zemp, D.C. *et al.* (2017) 'Self-amplified Amazon forest loss due to vegetation-atmosphere feedbacks', *Nature Communications*, 8(1), p. 14681. Available at: <https://doi.org/10.1038/ncomms14681>.

Zhang, H. *et al.* (2022) 'A novel red-edge spectral index for retrieving the leaf chlorophyll content', *Methods in Ecology and Evolution*, 13(12), pp. 2771–2787. Available at: <https://doi.org/10.1111/2041-210X.13994>.